



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

**DESENVOLVIMENTO DE METODOLOGIA PARA DETECÇÃO DE  
VAZAMENTOS DE ÓLEO NO MAR UTILIZANDO INTELIGÊNCIA  
ARTIFICIAL**

**Nájla Vilar Aires de Moura**

Tese de Doutorado

Brasília-DF: março/2023



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

# **DESENVOLVIMENTO DE METODOLOGIA PARA DETECÇÃO DE VAZAMENTOS DE ÓLEO NO MAR UTILIZANDO INTELIGÊNCIA ARTIFICIAL**

Nájla Vilar Aires de Moura

Orientador: Prof. Dr. Osmar Abílio de Carvalho Júnior

Tese de Doutorado

Brasília-DF: Março/2023



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

# **DESENVOLVIMENTO DE METODOLOGIA PARA DETECÇÃO DE VAZAMENTOS DE ÓLEO NO MAR UTILIZANDO INTELIGÊNCIA ARTIFICIAL**

Nájla Vilar Aires de Moura

Tese de Doutorado submetida ao Departamento de Geografia da Universidade de Brasília, como parte dos requisitos necessários para a obtenção do Grau de Doutora em Geografia, área de concentração Gestão Ambiental e Territorial, opção Acadêmica.

Aprovado por:

---

Prof. Dr. Osmar Abílio de Carvalho Júnior (Universidade de Brasília)  
(Orientador)

---

Prof. Dr. Edson Eyji Sano (Universidade de Brasília)  
(Examinador Interno)

---

Prof. Dr. Manoel do Couto Fernandes (Universidade Federal do Rio de Janeiro)  
(Examinador Externo)

---

Prof. Dr. Raúl Sánchez Vicens (Universidade Federal Fluminense)  
(Examinador Externo)

Brasília-DF, 24 de março de 2023.



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

DE MOURA, NÁJLA VILAR AIRES

Desenvolvimento de metodologia para detecção de vazamentos de óleo no mar utilizando inteligência artificial, 88 p. (UnB-PPGGEA, Tese, Gestão Ambiental e Territorial, 2023).

Tese de Doutorado – Universidade de Brasília, Programa de Pós-Graduação em Geografia

1. Sensoriamento Remoto
2. Deep Learning
3. Gestão de Desastres
4. Gestão Ambiental
5. Monitoramento

É concedida à Universidade de Brasília permissão para reproduzir cópias desta tese e emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. A autora reserva outros direitos de publicação e nenhuma parte desta tese de doutorado pode ser reproduzida sem a autorização por escrito da autora.

---

Nájla Vilar Aires de Moura



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

A todos aqueles que dedicam (e as vezes  
perdem) sua vida à causa ambiental.  
A minha mãe (*in memoriam*).



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

## **AGRADECIMENTOS**

Agradeço à Deus, porque até aqui me sustentou.

Agradeço ao meu orientador Prof. Dr. Osmar Abílio de Carvalho Júnior, pelo apoio e orientação.

Agradeço ao meu esposo Beto, pela paciência e parceria.

Agradeço aos amigos Vitor, Pedro, Verônica e Felipe pelo incentivo e interesse no andamento desta pesquisa.



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

## SUMÁRIO

<b>RESUMO</b> .....	VIII
<b>ABSTRACT</b> .....	IX
<b>LISTA DE FIGURAS</b> .....	X
<b>LISTA DE TABELAS</b> .....	XI
<b>LISTA DE ABREVIATURAS E SIGLAS</b> .....	XII
<b>CAPÍTULO I</b> .....	1
<b>OBJETIVOS</b> .....	11
<b>ESTRUTURA DA TESE</b> .....	11
<b>REFERÊNCIAS</b> .....	12
<b>CAPÍTULO II</b> .....	15
<b>II.1 INTRODUÇÃO</b> .....	16
<b>II.2 ACIDENTES SIGNIFICATIVOS</b> .....	17
<b>II.3 LEGISLAÇÃO</b> .....	19
<b>II.4 OUTROS INSTRUMENTOS DE GESTÃO</b> .....	23
<b>II.5 A APLICAÇÃO DOS PRINCÍPIOS DO PNC NA PRÁTICA</b> .....	25
<b>II.6 O USO DO SENSORIAMENTO REMOTO</b> .....	26
<b>II.7 CONCLUSÃO</b> .....	28
<b>REFERÊNCIAS</b> .....	29
<b>CAPÍTULO III</b> .....	34



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

<b>III.1 INTRODUÇÃO.....</b>	<b>35</b>
<b>III.2 SENSORES USADOS PARA DETECTAR MANCHAS DE ÓLEO E SUAS CARACTERÍSTICAS</b>	<b>36</b>
<b>III.3 CARACTERÍSTICAS DO SAR E SUA APLICAÇÃO NA IDENTIFICAÇÃO DE MANCHAS DE ÓLEO .....</b>	<b>38</b>
<b>III.4 CARACTERÍSTICAS DAS MANCHAS DE ÓLEO E FALSO-POSITIVOS PRESENTES NAS IMAGENS SAR.....</b>	<b>38</b>
<b>III.5 PESQUISAS PARA IDENTIFICAÇÃO DE MANCHAS DE ÓLEO EM IMAGENS SAR .....</b>	<b>39</b>
<b>III.6 DESAFIOS PARA A AUTOMAÇÃO.....</b>	<b>44</b>
<b>III.7 CONSIDERAÇÕES FINAIS .....</b>	<b>45</b>
<b>AGRADECIMENTOS .....</b>	<b>45</b>
<b>REFERÊNCIAS .....</b>	<b>45</b>
<b>CAPÍTULO IV.....</b>	<b>49</b>
<b>VI.1. INTRODUCTION .....</b>	<b>50</b>
<b>VI.2 MATERIAL AND METHODS.....</b>	<b>53</b>
<b>VI.3. RESULTS .....</b>	<b>59</b>
<b>VI.4. DISCUSSION .....</b>	<b>66</b>
<b>5. CONCLUSION.....</b>	<b>67</b>
<b>References.....</b>	<b>68</b>
<b>CAPÍTULO V .....</b>	<b>74</b>





Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

## RESUMO

Vazamentos de óleo no mar são de grande preocupação pública por representarem riscos para o meio ambiente, para a população costeira, além de perdas econômicas significativas. Com o crescimento da exploração do petróleo e da movimentação de navios aumenta a possibilidade de acidentes. Neste contexto, o sensoriamento remoto é uma tecnologia indispensável para a detecção e monitoramento das manchas de óleo na superfície marítima. A presente tese tem como objetivo analisar como é feita a gestão ambiental dos acidentes envolvendo vazamentos de óleo no mar no Brasil, seus instrumentos legais e programas de governo, bem como analisar o uso do sensoriamento remoto e propor uma metodologia de detecção de manchas de óleo a partir de técnicas de inteligência artificial (*deep learning*). Para isso, o trabalho traz uma revisão das pesquisas recentes desenvolvidas na detecção de vazamentos de óleo com o uso de imagens de satélite. Nessa etapa, o Radar de Abertura Sintética (SAR) destacou-se como o sensor mais usado, por ser eficiente mesmo com a presença de nuvens e no período noturno. A partir dessa constatação, utilizou uma série temporal de imagens do satélite Sentinel-1, equipado com SAR, como insumo para a criação de um banco de dados sobre derramamentos de óleo ocorridos na Bacia de Campos, litoral do Sudeste brasileiro, comparando diferentes modelos de aprendizado de máquina profundo (*deep learning*). O estudo verificou que das três arquiteturas de segmentação semântica (U-net, DeepLabv3+ e LinkNet) com quatro *backbones* (ResNet-101, ResNet-50, Efficient-net-B0 e Efficient-net-B3), resultando em 12 modelos, a que obteve o melhor resultado foi a U-net com o *backbone* Efficient-net-B3 (98% de acurácia, 75% de precisão, 78% de chamada, 76% de F-score e 62% de IoU). Além disso, a análise de recorrência detectou as áreas mais suscetíveis à ocorrência de vazamentos e foi capaz de eliminar falsos-positivos.

**Palavras-chave:** Sensoriamento Remoto, *Deep Learning*, Gestão de Desastres, Gestão Ambiental, Monitoramento



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

## ABSTRACT

Oil spills at sea are great public concern because they represent risks to the environment, to the coastal population, in addition to significant economic losses. With the growth of oil exploration and the movement of ships, the possibility of accidents increases. In this context, remote sensing is an indispensable technology for detecting and monitoring oil slicks on the sea surface. This thesis aims to analyze how the environmental management of accidents involving oil spills at sea in Brazil is carried out, its legal instruments and government programs, as well as to analyze the use of remote sensing and propose a methodology for detecting oil slicks based on artificial intelligence techniques (deep learning). For this, the work brings a review of recent research developed in the detection of oil leaks using satellite images. At this stage, the Synthetic Aperture Radar (SAR) stood out as the most used sensor, as it is efficient even with the presence of clouds and at night. Based on this observation, we used a time series of images from the Sentinel-1 satellite, equipped with SAR, as input for the creation of a database on oil spills that occurred in the Campos Basin, on the coast of southeastern Brazil, comparing different models of deep machine learning. The study verified that of the three semantic segmentation architectures (U-net, DeepLabv3+ and LinkNet) with four backbones (ResNet-101, ResNet-50, Efficient-net-B0 and Efficient-net-B3), resulting in 12 models, the that obtained the best result was the U-net with the Efficient-net-B3 backbone (98% accuracy, 75% precision, 78% recall, 76% F-score and 62% IoU). In addition, the recurrence analysis detected the areas most susceptible to leaks and was able to eliminate look-alike.

**Key words:** Remote Sensing, Deep Learning, Disaster management, Environmental Management, Monitoring



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

## LISTA DE FIGURAS

FIGURA 1 – Bacias Sedimentares Brasileiras.....	2
FIGURA 2 – Produção de petróleo no Brasil entre 2011 e 2020 em milhões de barris/dia.....	4
FIGURA 3 – Registros de vazamentos de óleo no mar entre 2012 e 2021 relacionados à exploração e produção offshore de petróleo e gás.....	5
FIGURA 4 – Satélite Sentinel-1 (A). Fotografia aérea de vazamento de óleo no mar (B). Imagem Sentinel-1 (C). .....	9



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

## LISTA DE TABELAS

TABELA 1 – Produção e consumo de petróleo no Brasil e no mundo (2011/2020).....	1
TABELA 2 – Reservas petrolíferas brasileiras. ....	3
TABELA 3 – Número de poços produtores de petróleo e de gás natural no Brasil entre 2011 e 2020 .....	4



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

## LISTA DE ABREVIATURAS E SIGLAS

ANP – Agência Nacional do Petróleo, Gás Natural e Biocombustíveis

CBERS-4 – *China-Brazil Earth Resources Satellite 4*

CONAMA – Conselho Nacional de Meio Ambiente

COVID – *Corona Virus Disease*

DL – *Deep Learning*

IBAMA – Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis

IEA – *International Energy Agency*

IPEA – Instituto de Pesquisas Econômicas Aplicadas

PIB – Produto Interno Bruto

SAR – *Sinthetic Aperture Radar*

SIEMA – Sistema de Emergências Ambientais



## CAPÍTULO I

### INTRODUÇÃO

O petróleo é a principal fonte de energia do planeta e a base para inúmeras cadeias produtivas. Seus derivados são matéria-prima para a indústria química, em especial, com aplicações na produção de diversos itens, como: cosméticos, plásticos, borrachas, tintas, tecidos, etc. (SAPNKEN e TAMBA, 2022). A produção e o consumo desse mineral é, portanto, fundamental para a economia global.

A demanda tem aumentado sobremaneira nas últimas décadas, acompanhando o crescimento populacional e do consumo (ANP, 2021). Mesmo com o declínio global da produção e do consumo ocorrido em 2020 (Tabela 1), em decorrência da pandemia de COVID-19, estima-se que a tendência de crescimento seja retomada, voltando aos patamares anteriores (IEA, 2022).

Tabela 1 - Produção e consumo de petróleo no Brasil e no mundo (2011/2020).

		Produção (mil barris/dia)										
		2011	2012	2013	2014	2015	2016	2017	2018	2019	2020	20/19%
Total		84.042	86.255	86.670	88.834	91.632	91.989	92.568	94.852	94.961	88.391	-6,92
Brasil		2.173	2.132	2.096	2.341	2.525	2.591	2.721	2.679	2.876	3.026	5,19
		Consumo (mil barris/dia)										
		2011	2012	2013	2014	2015	2016	2017	2018	2019	2020	20/19%
Total		87.530	88.607	89.988	90.677	92.787	94.381	96.099	97.265	97.598	88.477	-9,35
Brasil		2.432	2.509	2.655	2.725	2.558	2.433	2.481	2.392	2.438	2.323	-4,75

Fonte: ANP (2021).

No cenário internacional, o Brasil se destaca, sendo o nono maior produtor de petróleo do mundo, o primeiro da América Latina e de todo o Hemisfério Sul (ANP, 2021). A indústria petrolífera brasileira representa parte significativa da economia do país, totalizando 11% do PIB, além de constituir 33,1% da reserva de energia nacional (MORAIS e OLIVEIRA, 2022). No ano de 2020, a produção de petróleo total somou 1,076 bilhão de barris (ANP, 2021). Ao



contrário do que ocorreu no mercado internacional em 2020 o Brasil foi uma das poucas nações que aumentou sua produção (5,19% com relação ao ano anterior) (Tabela 1).

As principais áreas produtoras do país localizam-se nas Bacias Sedimentares de Santos e Campos, litoral da região Sudeste (Figura 1). No ano de 2021, esses dois locais produziram respectivamente 118.602.609 m<sup>3</sup> de petróleo (70,3% da produção nacional) e 43.829.712 m<sup>3</sup> (25,9% da produção nacional) (ANP, 2022a).

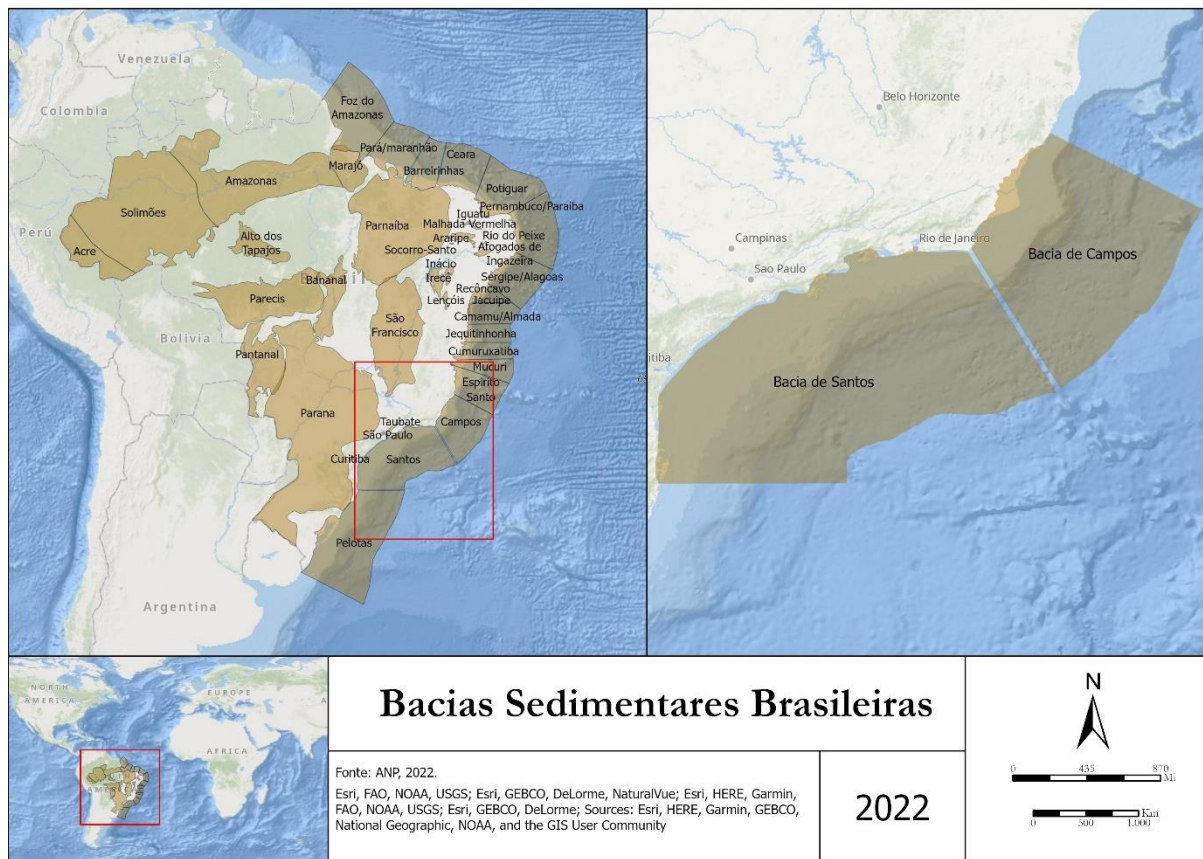


Figura 1 – Bacias Sedimentares Brasileiras.

A estimativa da reserva total de petróleo no mar territorial brasileiro somou em 2020 o montante de 19.549,1 milhões de barris. Estando a sua maior parte (19.347,6 milhões de barris) localizada na costa dos estados de Espírito Santo, São Paulo e Rio de Janeiro. Adicionalmente, o país conta com uma reserva em terra de 689,2 milhões de barris (ANP, 2021) (Tabela 2).



Destaca-se o aumento constante ocorrido na última década na produção no mar (produção *offshore*), que totalizou 97% do total em 2020, com declínio da produção em terra (Figura 2).

Tabela 2 – Reservas petrolíferas brasileiras.

UF	Local	Reservas totais de petróleo (milhões de barris)										20/19 %
		2011	2012	2013	2014	2015	2016	2017	2018	2019	2020	
<b>Brasil</b>		<b>30.081,8</b>	<b>28.555,2</b>	<b>30.181,1</b>	<b>31.106,6</b>	<b>24.390,7</b>	<b>22.657,1</b>	<b>23.580,3</b>	<b>24.308,6</b>	<b>21.813,8</b>	<b>20.238,3</b>	<b>-7,22</b>
<b>Subtotal</b>	<b>Terra</b>	<b>1.576,3</b>	<b>1.475,5</b>	<b>1.444,8</b>	<b>1.169,8</b>	<b>951,8</b>	<b>1.042,1</b>	<b>906,3</b>	<b>703,4</b>	<b>604,5</b>	<b>689,2</b>	<b>14,01</b>
	<b>Mar</b>	<b>28.505,5</b>	<b>27.079,6</b>	<b>28.736,3</b>	<b>29.936,8</b>	<b>23.438,9</b>	<b>21.615,0</b>	<b>22.674,1</b>	<b>23.605,3</b>	<b>21.209,3</b>	<b>19.549,1</b>	<b>-7,83</b>
AM	Terra	192,3	168,6	167,0	89,6	61,9	49,7	45,8	45,7	47,6	51,5	<b>8,27</b>
MA	Terra	-	-	0,1	0,0	0,1	0,1	0,3	0,3	0,2	0,2	<b>6,99</b>
CE	Terra	17,6	31,0	31,2	30,4	19,6	4,1	0,7	3,6	2,6	0,2	<b>-90,66</b>
	Mar	92,7	66,2	79,9	61,7	25,2	44,6	12,6	28,3	27,8	-	<b>..</b>
RN	Terra	351,3	355,6	335,9	326,6	246,9	243,4	231,9	162,8	168,9	176,8	<b>4,70</b>
	Mar	197,8	191,6	186,8	176,6	128,6	119,5	118,2	108,7	106,3	89,4	<b>-15,87</b>
AL	Terra	21,2	14,6	16,1	14,0	12,3	8,0	8,6	5,4	5,2	3,9	<b>-24,88</b>
	Mar	0,7	0,6	1,0	0,8	0,7	0,5	0,4	0,3	0,2	0,1	<b>-32,99</b>
SE	Terra	319,4	306,9	294,2	296,1	272,4	334,3	344,9	232,7	169,4	172,8	<b>1,98</b>
	Mar	116,5	126,1	104,9	98,9	78,0	46,6	3,8	7,0	25,4	22,0	<b>-13,34</b>
BA	Terra	597,2	522,6	531,4	343,2	286,8	346,8	224,1	207,7	161,3	204,0	<b>26,46</b>
	Mar	127,7	127,1	124,0	96,0	90,7	90,9	90,6	90,9	89,9	89,9	<b>-0,01</b>
ES	Terra	77,3	76,3	69,0	69,9	51,9	55,7	50,0	45,1	49,3	79,7	<b>61,68</b>
	Mar	2.851,9	2.676,4	2.446,9	2.300,6	2.196,8	1.910,3	1.788,7	1.630,0	1.343,6	1.235,2	<b>-8,07</b>
RJ	Mar	23.081,5	22.135,8	24.017,6	25.618,8	19.757,4	18.441,1	19.731,9	20.184,1	18.685,4	16.032,9	<b>-14,20</b>
SP	Mar	1.949,3	1.665,4	1.685,3	1.535,5	1.161,5	961,5	927,8	1.556,0	930,7	2.079,6	<b>123,44</b>
PR	Terra	0,0	-	-	-	-	-	-	-	-	-	<b>..</b>
	Mar	39,6	42,6	42,2	-	-	-	-	-	-	-	<b>..</b>
SC	Mar	47,8	47,8	47,8	47,8	-	-	-	-	-	-	<b>..</b>

Fonte: ANP (2021). <https://www.gov.br/anp/pt-br/centrais-de-conteudo/publicacoes/anuario-estatistico/arquivos-anuario-estatistico-2021/tabelas-e-quadros/industria-nacional-do-petroleo/t2-3.xls>



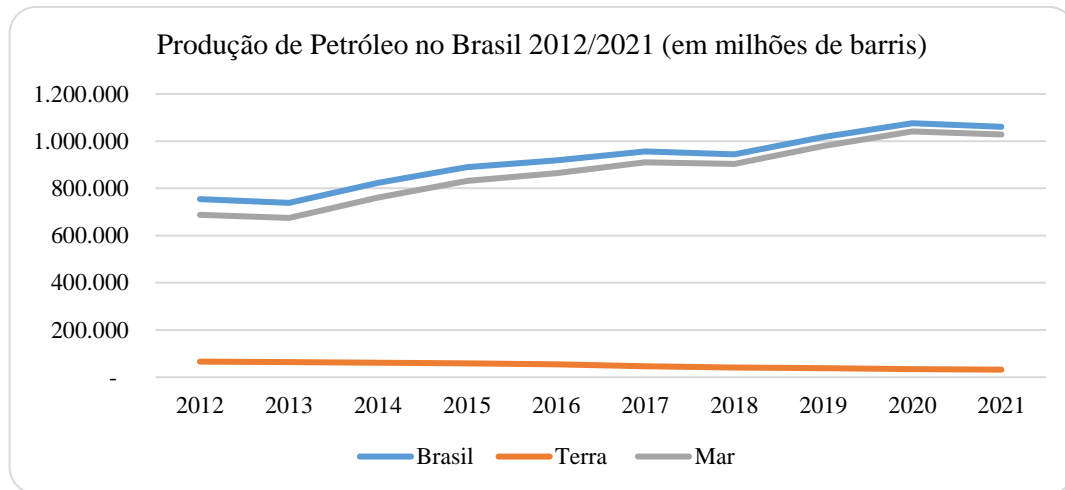


Figura 2 – Produção de petróleo no Brasil entre 2012 e 2021 em milhões de barris por dia (ANP, 2022a).

Embora a produção de petróleo tenha crescido constantemente nos anos passados, o mesmo não ocorreu com o número de poços produtores (Tabela 3). Esse declínio representa o descomissionamento de poços antigos que tiveram suas reservas esgotadas ou reduzidas a ponto de deixarem de ser economicamente viáveis e a abertura de novos poços com elevada produtividade, sobretudo aqueles localizados da região do pré-sal.

Tabela 3 – Número de poços produtores de petróleo e de gás natural no Brasil entre 2011 e 2020 (ANA, 2021).

Localização	2011	2012	2013	2014	2015	2016	2017	2018	2019	2020	20/19 %
Brasil - total	9.044	9.018	8.994	9.104	8.892	8.527	7.989	7.357	7.205	6.489	-9,94
Terra	8.275	8.227	8.229	8.263	8.106	7.772	7.196	6.650	6.575	5.990	-8,9
Mar	769	791	765	841	786	755	793	707	630	499	-20,79

A despeito da sua importância econômica, a expansão da produção de petróleo – não só no Brasil, mas em todo o mundo, em virtude da demanda crescente gerada pelo aumento populacional, industrial e no fluxo de transportes – acarreta a escalada do número de derramamentos de óleo<sup>1</sup> nos oceanos (YEKEEN e BALOGUN, 2020).

<sup>1</sup> A palavra óleo é usada ao longo do texto conforme definição da Lei nº 9966/2000 (Lei do Óleo), segundo a qual: óleo é “qualquer forma de hidrocarboneto (petróleo e seus derivados), incluindo óleo cru, óleo combustível, borra, resíduos de petróleo e produtos refinados” (BRASIL, 2000).



Os danos ambientais provocados por esses eventos, geram significativa preocupação pública e governamental, fato que ressalta a necessidade de detecção precoce para garantir sucesso da ação de resposta e da mitigação dos impactos (KERAMITSOGLOU et al., 2006). Sobretudo, considerando que os vazamentos – provenientes de navios ou de plataformas de exploração de petróleo, sejam eles acidentais ou intencionais – representam grande ameaça aos ecossistemas marítimos (TOPOUZELIS, 2008; AMIR-HEIDARI et al., 2019) e à saúde humana (DENIC-ROBERTS et al., 2022; JAYASREE et al., 2019).

A imiscibilidade entre o óleo e a água faz com que, em condições meteoceanográficas adequadas, seja formado um filme que pode permanecer na superfície por vários dias e se deslocar por muitos quilômetros até atingir áreas sensíveis localizados à longa distância do ponto de origem, o que pode ter efeitos ambientais e econômicos catastróficos.

Segundo dados da Agência Nacional do Petróleo, Gás Natural e Biocombustíveis - ANP (2022) foram registrados, entre os anos de 2012 e 2021, 634 incidentes envolvendo descarga de óleo (Figura 3) durante atividades de produção de petróleo. Destaca-se o aumento significativo do volume vazado nos anos de 2019 e 2020, respectivamente 411 m<sup>3</sup> e 214 m<sup>3</sup>.

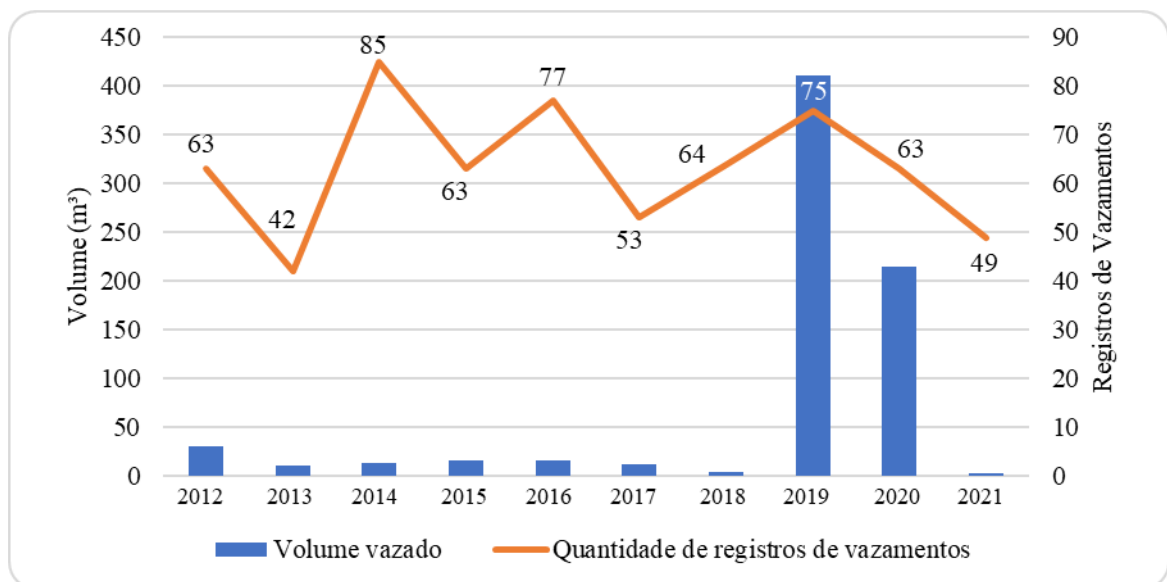


Figura 3 – Registros de vazamentos de óleo no mar entre 2012 e 2021 relacionados à exploração e produção offshore de petróleo e gás.



De maneira divergente, dados do Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis - IBAMA (2022) apresentam números superiores para um período inferior ao considerado pela ANP (o registro do IBAMA passou a ser feito regularmente somente a partir de 2015). Foram encontrados 843 registros de vazamento de óleo (aqui foi contabilizado somente os comunicados feitos pelas empresas produtoras em que foi explicitamente informado a ocorrência de vazamento para o mar de hidrocarboneto).

Adicionalmente, a base de dados contabiliza a ocorrência 963 vazamentos de óleo lubrificante, fluido hidráulico, fluido de perfuração. Essas substâncias podem conter a presença de hidrocarbonetos, mas o registro foi feito sem a especificação da composição. A base de dados ainda possui 88 entradas informando a ocorrência de “vazamento de origem indeterminada”, “mancha de origem desconhecida”, “mancha órfã”, sem a confirmação que se trata de óleo (IBAMA, 2022). Dessa forma, os números do IBAMA são superiores ao da ANP, podendo ainda estar subestimado, uma vez que o banco não apresenta dados completos.

As duas bases de dados são construídas de maneira distinta, explicando a discrepância dos números. Primordialmente, em ambos, os dados são oriundos dos comunicados de acidentes preenchidos e encaminhando pelas próprias empresas petrolíferas para a ANP e para o IBAMA (além da Marinha do Brasil), em atendimento à exigência estabelecida pelo Art. 22 da Lei nº 9.966/2000 – Lei do Óleo (BRASIL, 2000). Dessa forma, esses registros contam com a boa-fé das empresas para manter sua proximidade com a realidade. Portanto, podendo estar subestimado, uma vez que cabe ao poluidor identificar o vazamento e informar aos órgãos governamentais sua ocorrência.

Adicionalmente, o banco de dados do IBAMA conta com informações oriundas do monitoramento realizado por sensores remotos. Sobretudo, usando satélites com dados de acesso público, como Sentinel-1 (SAR), Sentinel-2, CBERS-4, Landsat-8 (óticos), além de registros feitos por servidores durante sobrevoos e até mesmo oriundos de denúncias. As divergências dos dados indicam a importância do monitoramento autônomo da costa brasileira pelo poder público.

Outra situação que causa preocupação pelo potencial de gerar poluição por óleo no mar é o lançamento de água de produção (ou água produzida) pelas plataformas que pode conter parcela significativa de óleo e outras substâncias nocivas ao meio ambiente (VIEIRA, 2003). A



água de produção é um rejeito líquido contendo substâncias químicas e orgânicas em suspensão ou diluídas, incluindo hidrocarbonetos, carregadas até a superfície no momento da extração de petróleo e gás (JIANG et al., 2021; COHA et al., 2021).

Embora a liberação de água de produção seja parte do processo produtivo da extração do petróleo, ela deve estar dentro de especificações estabelecidas pela Resolução CONAMA nº 393/2007 (BRASIL, 2007) visando reduzir os impactos ambientais. Um dos importantes parâmetros de enquadramento da água de produção é o teor de óleos e graxas.

Caso a liberação desse rejeito esteja fora de especificação, a empresa está passível de sanção por descumprimento da legislação. Essas ocorrências também devem ser notificadas aos órgãos governamentais. De maneira similar, os dados oficiais pesquisados divergem nesse ponto. Em 2020 a ANP registrou 60 vazamentos de água de produção fora de especificação e 50 em 2021 (ANP, 2021; 2022). Já o banco do IBAMA conta com apenas 10 registro de descarte de água de produção fora de especificação (IBAMA, 2022) ao longo de toda a série.

A partir dos dados encontrados, percebe-se a necessidade de que o Estado brasileiro seja apto a realizar o monitoramento dos oceanos de maneira autônoma, visando a obtenção de dados confiáveis que possam subsidiar ações de controle ambiental. Atendendo esse propósito, os insumos de sensoriamento remoto e técnicas de geoprocessamento são tecnologias consagradas que permitem a identificação de óleo no mar de maneira independente e eficiente pelo Estado (MOURA et al., 2020).

Esses insumos permitem a identificação precoce, fundamental para que possam ser adotadas ações de resposta e contenção antes do óleo atingir praias e outros ambientes sensíveis (YEKEEN e BALOGUN, 2020). Além de auxiliar na responsabilização dos autores do ilícito e permitir a obtenção de informações essenciais, tais como tamanho e limites da mancha, rota e velocidade do deslocamento, que contribuirão para a adoção de ações de resposta.

O monitoramento remoto pode ser utilizado tanto em situações em que o volume de óleo vazado é elevado, quanto naquelas com volumes menores, por vezes diluídos na água, decorrentes de ações intencionais, como o lançamento de água de produção, lavagens em embarcações ou de liberação de água de lastro (BREKKE e SOLBERG, 2005). Essas ocorrências têm maior incidência e são de mais difícil detecção, sobretudo por não possuírem localização conhecida (no caso de navios), ao contrário das plataformas de exploração de



petróleo. Em virtude da frequência elevada, os lançamentos intencionais de óleo no mar são ameaças maiores ao ambiente marítimo que os acidentes que envolvem grandes quantidades de óleo. Sendo de fundamental importância a vigilância e o monitoramento como medidas de controle e prevenção (ENGELHARD et al., 1999; BREKKE e SOLBERG, 2005).

Segundo Fingas e Brown (2014) diversos usos do sensoriamento remoto podem ser aplicados em eventos de derramamento de óleo e gerenciamento de desastres, tais como: mapeamento dos vazamentos, detecção e vigilância das manchas, elaboração de provas para acusação, fiscalização sobre normas de descarga de navios, estabelecimento de trajetória de manchas.

Diversos sensores são usados para o monitoramento de vazamentos de óleo no mar: óticos, infravermelhos, ultravioleta e radares (MOURA et al., 2020; JHA et al., 2008). Esse último predomina na literatura por ser um sensor ativo, portanto, capaz de adquirir imagens sob quaisquer condições climáticas e de luminosidade, podendo atuar inclusive durante a noite e com a presença de camadas de nuvens (MOURA et al., 2020; YEKEEN e BALOGUN, 2020; BREKKE e SOLBERG, 2005).

Destaca-se que o acesso a essas imagens avançou significativamente na última década, sobretudo com a disponibilização pública e gratuita da constelação Sentinel-1, da *European Space Agency* (ESA), que se contrapõe aos elevados custos das imagens anteriormente existentes (TOPOUZELIS e SINGHA, 2016).

A lógica de funcionamento dos radares no monitoramento de óleo no mar é bastante simples: a presença da substância na superfície cria um filme que arrefece a intensidade das ondas capilares formadas pelo vento, aplainando a superfície (Figura 4). Esse fenômeno aparece na imagem na forma de feições escuras, essa ocorrência se dá pelo fato de que na superfície plana as ondas emitidas pelo radar são espelhadas, ocorrendo retorno reduzido do sinal à antena do satélite. O contrário ocorre na superfície limpa, na qual a presença de ondas aumenta o sinal de retroespalhamento e retorno do sinal ao radar, gerando feições granuladas e mais claras (Figura 4-C).

No entanto, outros fenômenos também podem gerar feições escuras na imagem de radar, tais como células de chuva, áreas de baixo vento, filmes biogênicos, afloramentos naturais de óleo e outros (detalhados no Cap. 1), gerando falsos-positivos (*lookalikes*).



O processamento das imagens de radar e a discriminação visual das feições escuras podem consumir tempo e demandar grande força de trabalho. Por isso a literatura especializada no assunto apresenta inúmeras tentativas de aperfeiçoar as técnicas existentes para o uso de imagens de radar e tornar os procedimentos mais acurados e autônomos.




Figura 4 – Satélite Sentinel-1 (A). Fotografia aérea de vazamento de óleo no mar (B). Imagem Sentinel-1 (C).

Brekke e Solberg (2005) desenvolvem um algoritmo para detecção automática de vazamentos de óleo em imagens SAR, composto por 3 etapas (detecção de manchas escuras nas imagens, extração das características das manchas encontradas e classificação das manchas como sendo vazamentos de óleo ou feições de origens diversas – *lookalike*), seguido de estimativa de confiança dos dados encontrados. A avaliação sobre a estimativa de confiança da classificação depende do estabelecimento de diretrizes, sendo que algumas delas exigem



conhecimento das condições atmosféricas de momento da localidade (velocidade do vento, principalmente), da existência algas e do uso da área por navios ou plataformas, além da análise das características de cada mancha detectada (BREKKE e SOLBERG, 2005).

Gambardella et al. (2010) apresentam metodologia para detecção de vazamento de óleo baseada na classificação de apenas uma classe, utilizando amostras de treinamento apenas das áreas de mancha de óleo, ao contrário dos demais estudos que usam tanto amostras de vazamentos como de *lookalikes*. Os autores argumentam que este último não constitui de fato uma classe e sim um conjunto de diferentes fenômenos oceânicos e meteorológicos que aparecem nas imagens como manchas escuras e que podem ser confundidas como manchas causadas pela presença de óleo.

Topouzelis e Singha (2016) fazem apanhado sobre tendências recentes no uso de imagens de satélites para a detecção de vazamento de óleo no mar. Os autores afirmam que a principal mudança se encontra na maior disponibilidade de imagens, permitindo abundância de dados. Os autores afirmam que a metodologia permanece constante tanto para a análise manual como para a integralmente automática, não tendo apresentado variações significativas nas décadas recentes. Continuam as mesmas regras de detecção, com o uso de quatro passos metodológicos: detecção de áreas escuras, extração de características, criação de banco de dados estatísticos e classificação, estando essas em constante aperfeiçoamento nos estudos realizados. O principal problema na detecção de vazamentos de óleo é a correta discriminação entre vazamentos reais e *lookalikes*.

O trabalho de Brekke e Solberg (2005) afirma que para a potencialização dos resultados faz-se necessário um sistema integrando, usando algoritmos automáticos e banco de dados robusto contendo informações de diversos tipos (por exemplo, mapeamento de plataformas de petróleo, aflorações naturais, navios afundados, rotas de navio, presença de algas e condições do vento). E justamente essa é a maior limitação para desenvolvimento de pesquisas no Brasil, pois os bancos de dados oficiais são escassos, incompletos e de difícil interpretação.

Apesar do avanço de técnicas e metodologias de sensoriamento remoto, bem como do aumento da disponibilidade de insumos, a presença de *lookalikes* ainda é fator de atraso para a detecção de óleo e para a tomada de decisão em situações emergenciais (YEKEEN e BALOGUN, 2020). Por esse motivo, aumentaram nos anos recentes as tentativas de



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

desenvolver metodologias automatizadas para identificação de óleo baseadas em inteligência artificial, que demonstram resultados satisfatórios, com a capacidade de fornecer informações acuradas sobre as características do vazamento, como o seu centroide, tamanho e distância da costa (KERAMITSOGLOU et al., 2006).

Em especial, tem se intensificado o uso de metodologias baseadas em *Deep Learning* – aprendizado de máquina profundo, tecnologia do campo do aprendizado de máquina que teve crescimento significativo nos anos recentes no âmbito do sensoriamento remoto – visando reduzir o tempo de análise das imagens, eliminar os *lookalikes* e aumentar a acurácia dos resultados (Cap. 3).

Os algoritmos de *Deep Learning* possuem um grande número de camadas ocultas que permitem melhor abstração, previsão, generalização e transferibilidade de dados, além da capacidade de aprender de maneira autônoma, acarretando o aumento da performance e acurácia da detecção de óleo na água (YEKEEN e BALOGUN, 2020).

## **OBJETIVOS**

Nesse contexto, a presente pesquisa tem como objetivos:

- Analisar como ocorre a gestão ambiental dos vazamentos de óleo no Brasil, incluindo o arcabouço legal, os programas e projetos executados pelo Estado e as ações de monitoramento.
- Elaborar estudo sobre o estado da arte do uso do Sensoriamento Remoto e as diferentes metodologias existentes para identificação de vazamentos de óleo no mar em imagens de satélite, sobretudo, radar.
- Aplicar metodologia baseada em *Deep Learning* na identificação dos vazamentos de óleo nas imagens de radar obtidas da Bacia Sedimentar de Campos.

## **ESTRUTURA DA TESE**

O documento está organizado em 5 Capítulos, sendo que os Capítulos 2, 3 e 4 foram elaborados na forma artigos, por meio dos quais pretende-se consolidar e divulgar a pesquisa em âmbito nacional e internacional:

- Capítulo 1: Introdução.





Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

- Capítulo 2: análise da gestão ambiental de acidentes envolvendo vazamento de óleo no Brasil. Esse artigo foi submetido a Revista Espaço Aberto – PPGG-UFRJ.
- Capítulo 3: revisão da literatura sobre o uso de sensoriamento remoto da detecção de óleo, destacando o uso de imagens de radar e as metodologias que buscam a automação da tarefa. Esse artigo foi publicado na revista Caminhos da Geografia (DOI: 10.14393/RCG217551341).
- Capítulo 4: estudo sobre o estado-da-arte do uso *Deep Learning* e aplicação de metodologias para a identificação de vazamentos mapeados na Bacia Sedimentar de Campos. Esse artigo foi publicado na revista *International Journal of Applied Earth Observation and Geoinformation* (DOI: 10.1016/j.jag.2022).
- Capítulo 5: Conclusão.

## REFERÊNCIAS

AMIR-HEIDARI, P., ARNEBORG, L., LINDGREN, J.F., LINDHE, A., ROSÉN, L., RAIE, M., AXELL, L. e HASSELLÖV, I.M. A state-of-the-art model for spatial and stochastic oil spill risk assessment: A case study of oil spill from a shipwreck. **Environment International**, v. 126, p. 309-320, 2019. <https://doi.org/10.1016/j.envint.2019.02.037>

AGÊNCIA NACIONAL DO PETRÓLEO, GÁS NATURAL E BIOCMBUSTÍVEIS (ANP). **Anuário Estatístico 2021**. Brasília, 2021. Disponível em: <https://www.gov.br/anp/pt-br/centrais-de-conteudo/publicacoes/anuario-estatistico/anuario-estatistico-2021#Se%C3%A7%C3%A3o%202>. Acesso em: 12 ago. 2022.

AGÊNCIA NACIONAL DO PETRÓLEO, GÁS NATURAL E BIOCMBUSTÍVEIS (ANP). **Anuário Estatístico 2022**. Brasília, 2022a. Disponível em: <https://www.gov.br/anp/pt-br/centrais-de-conteudo/publicacoes/anuario-estatistico/anuario-estatistico-2022>. Acesso em: 17 jul. 2022.

AGÊNCIA NACIONAL DO PETRÓLEO, GÁS NATURAL E BIOCMBUSTÍVEIS (ANP). **Relatório Anual de Segurança Operacional das Atividades de Exploração e Produção de Petróleo e Gás Natural 2021**. Brasília, 2022b. Disponível em: [https://www.gov.br/anp/pt-br/assuntos/exploracao-e-producao-de-oleo-e-gas/seguranca-operacional-e-meio-ambiente/arq/raso/v0\\_2021\\_relatorio-anual-de-seguranca-operacional.pdf](https://www.gov.br/anp/pt-br/assuntos/exploracao-e-producao-de-oleo-e-gas/seguranca-operacional-e-meio-ambiente/arq/raso/v0_2021_relatorio-anual-de-seguranca-operacional.pdf). Acesso em: 12 jun. 2022.

BRASIL. **Lei nº 9.966/2000**, de 28 de abril de 2000. Lei do Óleo. Dispõe sobre a prevenção, o controle e a fiscalização da poluição causada por lançamento de óleo e outras substâncias



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

nocivas ou perigosas em águas sob jurisdição nacional e dá outras providências. Disponível em: [http://www.planalto.gov.br/ccivil\\_03/leis/19966.htm](http://www.planalto.gov.br/ccivil_03/leis/19966.htm)

BREKKE, Camilla; SOLBERG, Anne. HS. Feature extraction for oil spill detection based on SAR images. In: **Scandinavian Conference on Image Analysis**. Springer, Berlin, Heidelberg, p. 75-84, 2005. [https://doi.org/10.1007/11499145\\_9](https://doi.org/10.1007/11499145_9)

COHA, M., FARINELLI, G., TIRAFERRI, A., MINELLA, M. AND VIONE, D. Advanced oxidation processes in the removal of organic substances from produced water: Potential, configurations, and research needs. **Chemical Engineering Journal**, v. 414, p. 128668, 2021. <https://doi.org/10.1016/j.cej.2021.128668>

DENIC-ROBERTS, H., ROWLEY, N., HAIGNEY, M.C., CHRISTENBURY, K., BARRETT, J., THOMAS, D.L., ENGEL, L.S. AND RUSIECKI, J.A. Acute and longer-term cardiovascular conditions in the Deepwater Horizon Oil Spill Coast Guard Cohort. **Environment International**, v. 158, p. 106937, 2022. <https://doi.org/10.1016/j.envint.2021.106937>

ENGELHARDT, F. R. Remote sensing for oil spill detection and response. **Pure and applied chemistry**, v. 71, n. 1, p. 103-111, 1999. <https://doi.org/10.1351/pac199971010103>

INSTITUTO BRASILEIRO DO MEIO AMBIENTE E DOS RECURSOS NACIONAIS RENOVÁVEIS (IBAMA). **Siema - Comunicado de Acidente Ambiental**. 2022. Disponível em: <https://dadosabertos.ibama.gov.br/dataset/>. Acesso em: 01 jul. 2022.

INTERNATIONAL ENERGY AGENCY (IEA). **Oil Market Report - July 2022**, 2022. IEA, Paris. Disponível em: <https://www.iea.org/reports/oil-market-report-july-2022>. Acesso em: 23 jul. 2022.

JAYASREE, K., ENGEL, L.S., WANG, L., SCHWARTZ, E.G., CHRISTENBURY, K., KONDRUP, B., BARRETT, J. AND RUSIECKI, J.A. Neurological symptoms associated with oil spill response exposures: results from the Deepwater Horizon Oil Spill Coast Guard Cohort Study. **Environment International**, v. 131, p. 104963, 2019. <https://doi.org/10.1016/j.envint.2019.104963>

JIANG, W.; LIN, L.; XU, X.; CHENG, X.; ZHANG, Y.; HALL, R.; XU, P. A critical review of analytical methods for comprehensive characterization of produced water. **Water**, v. 13, n. 2, p. 183, 2021. <https://doi.org/10.3390/w13020183>

KERAMITSOGLU, I.; CARTALIS, C.; KIRANOUDIS, C. T. Automatic identification of oil spills on satellite images. **Environmental Modelling & Software**, v. 21, n. 5, p. 640-652, 2006. <https://doi.org/10.1016/j.envsoft.2004.11.010>

KRISHNAMURTHY, J., ENGEL, L. S., WANG, L., SCHWARTZ, E. G., CHRISTENBURY, K., KONDRUP, B., JOHN B., RUSIECKI, J. A. Neurological symptoms associated with oil spill response exposures: results from the Deepwater Horizon Oil Spill Coast Guard Cohort



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

Study. **Environment international**, v. 131, p. 104963, 2019.  
<https://doi.org/10.1016/j.envint.2019.104963>

MORAIS, J. M. e OLIVEIRA, J. M. **Tota Técnica nº 98 - O setor de petróleo no Brasil e os impactos do projeto de Lei nº 3.178/2019 no pré-sal**. IPEA. 2022. DOI:  
<http://dx.doi.org/10.38116/ntdiset98>

MOURA, N. V. A., DE CARVALHO, O. L. F., GOMES, R. A. T., GUIMARÃES, R. F., e DE CARVALHO JÚNIOR, O. A. Deep-water oil-spill monitoring and recurrence analysis in the Brazilian territory using Sentinel-1 time series and deep learning. **International Journal of Applied Earth Observation and Geoinformation**, v. 107, p. 102695, 2022.  
<https://doi.org/10.1016/j.jag.2022.102695>

MOURA, N.V.A., DE CARVALHO JÚNIOR, O.A., TRANCOSO GOMES, R.A., FONTES GUIMARÃES, R. Revisão sobre o uso de sensoriamento remoto na detecção de vazamentos de óleo no mar. **Caminhos de Geografia**. v. 21, n. 75, p. 214–224. 2020.  
<https://doi.org/10.14393/RCG217551341>

SAPNKEN, Flavian Emmanuel; TAMBA, Jean Gaston. Petroleum products consumption forecasting based on a new structural auto-adaptive intelligent grey prediction model. **Expert Systems with Applications**, p. 117579, 2022. <https://doi.org/10.1016/j.eswa.2022.117579>

YEKEEN, S. T.; BALOGUN, A. L. Advances in remote sensing technology, machine learning and deep learning for marine oil spill detection, prediction and vulnerability assessment. **Remote Sensing**, v. 12, n. 20, p. 3416, 2020. <https://doi.org/10.3390/rs12203416>

TOPOUZELIS, K.; KARATHANASSI, V.; PAVLAKIS, P.; ROKOS, D. Detection and discrimination between oil spills and look-alike phenomena through neural networks. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 62, n. 4, p. 264-270, 2007. <https://doi.org/10.1016/j.isprsjprs.2007.05.003>

TOPOUZELIS, Konstantinos N. Oil spill detection by SAR images: dark formation detection, feature extraction and classification algorithms. **Sensors**, v. 8, n. 10, p. 6642-6659, 2008. <https://doi.org/10.3390/s8106642>

TOPOUZELIS, Konstantinos; SINGHA, Suman. Oil spill detection: Past and future trends. In: **Proceedings of the ESA Living Planet Symposium**. Paris, France: European Space Agency (Special Publication), 2016. p. 387-402.

VIEIRA, Daniela Sayão; CAMMAROTA, Magali Christe; CAMPORESE, Eliana Flávia Sérvulo. Redução de contaminantes presentes na água de produção de petróleo. In: **2º Congresso Brasileiro de P&G em Petróleo & Gás**. Rio de Janeiro, 2003.



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

## CAPÍTULO II

### GESTÃO AMBIENTAL DE VAZAMENTOS DE ÓLEO NO MAR TERRITORIAL BRASILEIRO E O USO DO SENSORIAMENTO REMOTO

### ENVIRONMENTAL MANAGEMENT OF OIL SPILLS IN THE BRAZILIAN TERRITORIAL SEA AND THE USE OF REMOTE SENSING

Nájla Vilar Aires de Moura<sup>2</sup>  
Universidade de Brasília  
Brasília, Brasil

Osmar Abílio de Carvalho Júnior<sup>3</sup>  
Universidade de Brasília  
Brasília, Brasil

**Resumo:** O gerenciamento de desastres causados por vazamentos de óleo no mar brasileiro tem como alicerce a Lei nº 9.966/2000. No entanto, o seu atendimento representa desafio ao poder público, que ao longo dos últimos anos demonstrou dificuldades na execução da Lei. O presente artigo apresenta os instrumentos jurídicos e programas de Estado usados para auxiliar na tomada de decisão durante a ocorrência de acidentes, considerando como referência os três principais eventos ocorridos nas últimas duas décadas no Brasil, os quais indicam a ocorrência de falhas e, por vezes, inoperância das ações do Estado. O monitoramento desses eventos com o uso de sensoriamento remoto é discutido a partir da escassa produção científica disponível, o que evidencia a necessidade de estímulo à pesquisa e ao desenvolvimento de projetos que possam subsidiar a gestão dos acidentes, bem como indicam a necessidade de disponibilização de imagens de satélite do mar territorial brasileiro.

**Palavras-chave:** Poluição; Gestão Costeira; Gerenciamento de Desastres; Produção de Petróleo; Monitoramento Ambiental.

**Abstract:** Managing disasters caused by oil spills in the Brazilian sea is based on Law n. 9966/2000. However, its attendance represents a challenge to the public Power, which over the last few years has demonstrated difficulties in the execution of the Law. This article presents the legal instruments and State programs used to assist in decision-making during the

---

<sup>2</sup> Aluna do Doutorado do Programa de Pós-Graduação em Geografia, Departamento de Geografia da Universidade de Brasília. <https://orcid.org/0000-0002-8536-0640>, najlavilar@hotmail.com.

<sup>3</sup> Professor do Programa de Pós-Graduação em Geografia, Departamento de Geografia da Universidade de Brasília, <https://orcid.org/0000-0002-0346-1684>, osmarjr@unb.br.



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

occurrence of accidents, considering as reference the three main events that occurred in the last two decades in Brazil, which indicate the occurrence of failures and, sometimes, ineffectiveness of State actions. The monitoring of these events with the use of remote sensing is discussed based on the scarce scientific production available, which highlights the need to encourage research and the development of projects that can support the management of accidents, as well as indicating the need to make available satellite images of the Brazilian territorial sea.

**Keywords:** Pollution; Coastal Management; Disaster Management; Oil Production; Environmental monitoring.

## II.1 INTRODUÇÃO

Derramamentos de óleo no mar representam grande preocupação pública no Brasil em virtude dos impactos imediatos causados nos ambientes costeiros, no turismo e na pesca, além de acarretarem atenção midiática significativa (MOURA et al., 2020). O óleo pode se acumular no solo e em sedimentos e contaminar a flora, a fauna e a água. Sua presença tem potencial de dano em praias e suas comunidades biológicas, podendo permanecer nesses ambientes por longos períodos, causando danos significativos, por exemplo, em manguezais, acarretando o comprometimento das atividades produtivas na área costeira (SOUSA et al., 2013). A presença de óleo na água atinge diretamente as atividades pesqueiras, podendo destruir equipamentos de pesca e instalações de maricultura, além de poder restringir essa atividade por longos períodos. Igualmente atinge atividades ligadas ao turismo, como navegação, mergulhos, natação (SOUSA et al., 2013). Além de poder causar insegurança alimentar em comunidades pesqueiras (AZEVEDO et al., 2022).

O petróleo bruto também representa grave ameaça à saúde quando ocorre exposição por ingestão, absorção e/ou inalação. Os riscos toxicológicos envolvidos são graves, agudos e crônicos que podem levar à morte por intoxicação. O petróleo contém uma variedade de toxinas conhecidas, com severas consequências para a saúde, incluindo: 1) compostos orgânicos voláteis (VOCs), conhecidos pela associação a doenças carcinogênicas, a efeitos hematotóxicos, imunotóxicos e disfunção renal, hepáticas e hormonais, irritação respiratória, transtornos mentais, especialmente quadros de depressão; 2) hidrocarbonetos policíclicos aromáticos (HPAs) conhecidas substâncias cancerígenas que podem alterar as funções reprodutivas e imunológicas em mulheres e homens; 3) sulfeto de hidrogênio que pode causar



efeitos agudos e crônicos do sistema nervoso central, como cefaleias, alterações da atenção, memória insuficiente e; 4) metais pesados, como arsênico, cádmio, cromo, manganês, cobre, níquel, vanádio e chumbo, que acarretam enfermidades, tais como lesões renais, neurotoxicidade, carcinogenicidade e imunotoxicidade (PENA et al., 2020).

Diante desses impactos severos, faz-se necessário a criação de mecanismos para evitar os acidentes que tenham como consequência o vazamento de óleo para o mar e o desenvolvimento de programas e novas metodologias de identificação e monitoramento dos vazamentos antes deles atingirem a costa e se dispersarem de maneira acelerada. Para tanto, o uso de tecnologias de Sensoriamento Remoto é primordial para o alcance desse objetivo (MOURA et al., 2020).

No Brasil, nas últimas décadas, três eventos são representativos dos impactos causados por grandes vazamentos de óleo em áreas costeiras. O acidente ocorrido na Baía da Guanabara em 2000; o vazamento ocorrido durante a perfuração de poço petrolífero pela empresa Chevron no Campo de Frade em 2011 e; o incidente de origem desconhecida que acarretou a poluição por óleo em todos os estados da região Nordeste, além de Espírito Santo e Rio de Janeiro, em 2019/2020.

Esses três acidentes ambientais marcantes na história brasileira são pano de fundo para a análise realizada no presente artigo, que apresenta o arcabouço legal sobre o assunto e os instrumentos de gestão usados pelo Estado no gerenciamento de desastres ambientais envolvendo o vazamento de óleo no litoral do país. Por fim, é discutido o uso do Sensoriamento Remoto nos três eventos e seu papel na gestão ambiental.

## **II.2 ACIDENTES SIGNIFICATIVOS**

O vazamento ocorrido na Baía da Guanabara, Rio de Janeiro, iniciou em 18 de janeiro de 2000, ocasião em que 1,3 milhão de litros de óleo combustível escaparam do oleoduto PE-II, oriundo da Refinaria de Duque de Caxias (REDUC), da Petrobras. Segundo a empresa o vazamento ocorreu em decorrência da expansão e contração térmica do duto, iniciou à 1 hora da manhã e foi somente constatado 5 horas após iniciado (ACSELRAD e MELLO, 2002; MONTEIRO, 2003).

Além de toda a Baía da Guanabara, o óleo atingiu diversas localidades: Ilha do Governador, Duque de Caxias, Magé, Mauá, Piedade, Ipiranga, Anil, Limão, Guapimirim, São



Gonçalo, Ilha de Paquetá e Itaboraí. Totalizando mais de 40 km de praias e inúmeras áreas de manguezais (SOUSA et al., 2013). O acidente poluiu a água e os sedimentos da Baía e causou impactos em peixes, crustáceos, aves, reptéis e mamíferos presentes nos habitats afetados. Do ponto de vista socioeconômico, 30 mil pessoas ligadas as atividades pesqueiras foram afetadas, seja pela morte de peixes, pela perda de equipamentos, pelos períodos de proibição de pesca estabelecidos e pela recusa de compradores adquirirem os produtos mesmo meses após o ocorrido (SOUSA et al., 2013).

Destaca-se que os estudos encontrados sobre esse acidente estão em sua maioria restritos aos 2 anos subsequentes ao evento, não tendo ocorrido acompanhamento posterior sobre a qualidade ambiental da área ou das condições socioeconômicas dos afetados. O único estudo de acompanhamento encontrado foi concluído em 2005 e tratou da caracterização química e biológica de amostras de sedimentos de mangues afetados (MACIEL-SOUZA et al., 2006).

Pouco mais de uma década depois desse acidente, em 07 de novembro de 2011, ocorreu outro derramamento de grandes proporções. Foram vazados 3.700 barris de petróleo durante a perfuração de um poço explorado pela concessionária Chevron Brasil, a aproximadamente 120 km da costa brasileira, no Campo Frade, Bacia de Campos. A empresa somente identificou o vazamento 2 dias após o seu início e só conseguiu controlar após 6 dias (ANP, 2012). O óleo vazado se deslocou no sentido sudeste, por isso não atingiu a costa. A mancha de óleo visível na superfície da água chegou a 68 km de extensão e área de cerca de 163 km<sup>2</sup> (CAMPOS, 2016). Não foram encontrados estudos científicos sobre os impactos ambientais desse acidente.

O evento de 2019/2020 constituiu-se no aparecimento de manchas de óleo de origem desconhecida em praias brasileiras. Seus primeiros registros ocorreram em 30 de agosto de 2019, no litoral do estado Paraíba, e posteriormente em Pernambuco e Sergipe, nordeste da costa brasileira. Nos meses subsequentes, atingido 11 estados (todos os da região Nordeste e 2 estados da região Sudeste), totalizando uma faixa litorânea de aproximadamente 3.500 km, do Maranhão até a costa norte do estado do Rio de Janeiro, atingindo 130 municípios e 1009 localidades, até 19 de março de 2020 (IBAMA, 2020a). Análises laboratoriais indicaram que as amostras coletadas foram oriundas de uma mesma fonte, até hoje desconhecida, com características similares de amostras de petróleo de origem venezuelana (NOBRE et al., 2021).



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

Durante o evento foram coletadas 5.300 toneladas de resíduos oleados e resgatados 159 animais oleados, sendo que 112 deles já estavam mortos (IBAMA, 2020a). Os impactos ambientais provocados pelo óleo ao atingir manguezais, praias, recifes, estuários, planícies de marés e outros habitats são imensuráveis. Além dos impactos socioeconômicos, principalmente ligados ao turismo e a pesca, cuja estimativa é de que envolvam respectivamente 365.657 pessoas (IPEA, 2019) e 503.692 indivíduos ligados à atividade pesqueira (DIAS NETO, 2017).

### **II.3 LEGISLAÇÃO**

O instrumento legal norteador das políticas públicas para a gestão de acidentes envolvendo óleo no Brasil é a Lei nº 9.966, de 28 de abril de 2000, conhecida como Lei do Óleo. Essa lei dispõe sobre a prevenção, o controle e a fiscalização da poluição causada por lançamento de óleo e outras substâncias nocivas ou perigosas em águas sob jurisdição nacional (BRASIL, 2000). Esse é um importante marco legislativo na esfera da responsabilidade civil e da reparação por desastre ambiental (COSTA, 2020).

Esse instrumento surgiu sob o impacto do derramamento de óleo ocorrido na Baía da Guanabara em 2000, esse acidente evidenciou lacunas de responsabilidades e orientação prática na gestão desse tipo de incidente no Brasil (SOUSA et al., 2013). Assim, a Lei estabeleceu os princípios a serem atendidos pelos operadores de atividades que envolvem a movimentação de óleo e outras substâncias nocivas em portos organizados, instalações portuárias, plataformas e navios (incluindo estrangeiros) em águas sob jurisdição nacional, e estabeleceu competências, em diferentes esferas de poder, para: Marinha do Brasil, Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis (IBAMA), Órgãos estaduais e municipais de meio ambiente e para a Agência Nacional do Petróleo (ANP).

O texto legal impõe a necessidade de que todos os portos e plataformas tenham sistemas de prevenção, controle e combate da poluição decorrente do vazamento de óleo, incluindo planos de emergência individuais para o combate à poluição. Esses planos de emergência individuais (PEI) devem ser posteriormente consolidados pelo órgão ambiental competente, na forma de planos de contingência locais (Planos de Área - PA) ou regionais (Plano Regional – PR), em articulação com os órgãos de defesa civil.





Ao IBAMA, também é atribuída a responsabilidade de consolidar os planos de contingência locais e regionais na forma do Plano Nacional de Contingência (PNC), em articulação com os órgãos de defesa civil. A definição dessas ferramentas é uma inovação da Lei, uma vez que cria o dever de prevenção e reparação de danos (COSTA, 2020). Destaca-se que o PNC foi somente regulamentado em 22 de outubro de 2013, pelo Decreto nº 8.127/13, após a ocorrência do acidente no Campo de Frade e do acidente sem precedentes na história ocorrido no Golfo no México oriundo da plataforma Deep Water Horizon (PEDROSA, 2012). A Figura 1 indica os níveis de abrangência de cada plano estabelecido pela Lei.

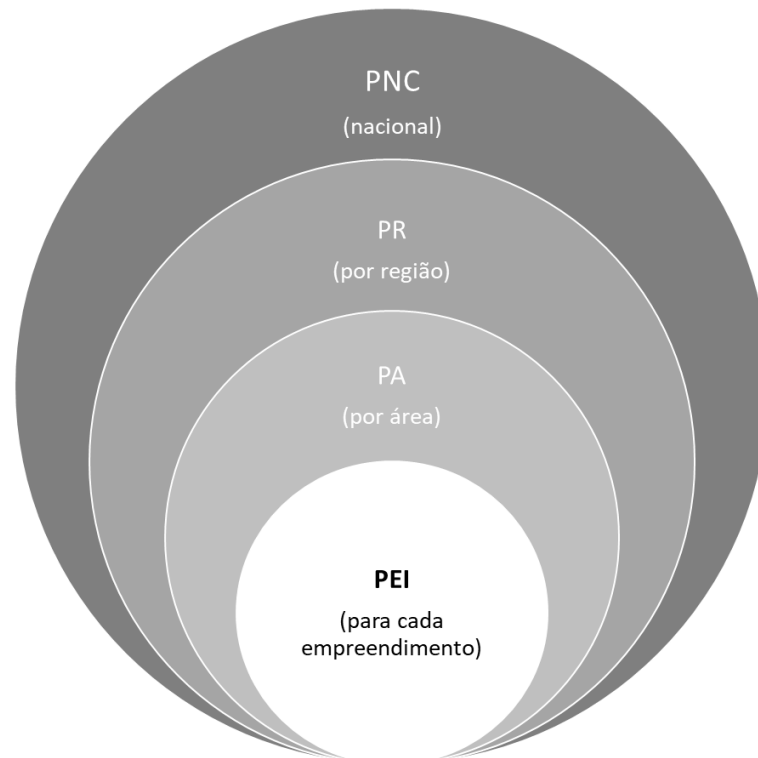


Figura 1 – Abrangência dos planos de respostas aos vazamentos de óleo estabelecidos pela Lei do Óleo.

Antes da promulgação da Lei do Óleo, o Brasil já era signatário de instrumentos internacionais que tratam do direito do mar, segurança de navegação e poluição marinha, a saber:

- i. Marpol 73/78: Convenção Internacional para a Prevenção da Poluição Causada por Navios, ocorrida em 2 de novembro de 1973, Londres, alterada pelo Protocolo de 1978,



em 17 de fevereiro de 1978, e emendas posteriores. Essa convenção teve como propósito o estabelecimento de regras para a eliminação da poluição intencional do meio ambiente por óleo e outras substâncias danosas oriundas de navios, bem como a minimização da descarga acidental daquelas substâncias no ar e no meio ambiente marinho (Marinha do Brasil, 2023a);

ii. CLC/69: Convenção Internacional sobre Responsabilidade Civil em Danos Causados por Poluição por Óleo, de 1969, ratificada pelo Brasil pelo Decreto nº 79.437, de 28 de março de 1977. Essa convenção teve por objetivo criar mecanismo internacional capaz de assegurar compensação adequada e acessível às vítimas de danos por poluição, resultantes de escapamento ou descarga de óleo proveniente de navios (Marinha do Brasil, 2023b);

iii. OPRC/90: International Convention on Oil Pollution Preparedness, Response and Co-Operation, 1990 (Convenção Internacional sobre Preparo, Resposta e Cooperação em Caso de Poluição por Óleo) ratificada pelo Brasil. Teve por objetivo promover a cooperação internacional e aperfeiçoar as capacidades nacional, regional e global de preparo e resposta à poluição por óleo, e, no caso do Protocolo, à poluição por substâncias potencialmente perigosas e nocivas (Marinha do Brasil, 2023c). Essa convenção foi realizada após o derramamento de óleo da Exxon Valdez (ocorrido no Alasca em 1989) e define que todo acidente deve ser reportado imediatamente às autoridades marítimas, que todo navio ou plataforma deve manter um estoque de equipamentos necessários para contenção de vazamentos e que exercícios simulados devem ocorrer frequentemente, a fim de evitar possíveis falhas operacionais.

Embora seja parte desses instrumentos, o Brasil não é atualmente signatário de nenhum dos fundos internacionais existentes para compensação de desastres ambientais, como o Fundo Internacional de Compensação por Danos Causados por Poluição por Petróleo (FUND 92). Dessa forma, a responsabilidade de arcar com todos os custos financeiro decorrente da poluição e das ações de respostas cabe ao poder público, quando não identificado o responsável, como no incidente de 2019/2020 (LAWAND, 2021).



Em 30 de outubro de 2019, foi submetida ao Senado Federal uma Proposta de Emenda Constitucional (PEC) de nº 184/2019, visando criar o Fundo Nacional de Responsabilidade por Poluição Causada por Incidentes com Hidrocarbonetos, tendo como justificativa o combate e a mitigação dos danos ambientais causados por incidentes com petróleo e seus derivados. Atualmente, a proposição encontra-se na Comissão de Constituição e Justiça do Senado, com a situação “Em tramitação”, aguardando a designação de relator, desde o dia 31/10/2019 (SENADO FEDERAL, 2023).

Após a promulgação da Lei do Óleo, outros instrumentos jurídicos surgiram para detalhar procedimentos e responsabilidades:

- i. Resolução CONAMA nº 269/2000 (revogada): estabelecia critérios para o uso de dispersantes químicos em incidentes de poluição por óleo no mar (substituída pela CONAMA nº 472/2015);
- ii. Resolução CONAMA nº 293/2001 (revogada): estabelecia o conteúdo mínimo dos Planos de Emergência Individual (PEI) (substituída pela CONAMA nº 398/2008);
- iii. Decreto nº 4.871/2003: institui os Planos de Áreas para o combate à poluição por óleo em águas sob jurisdição nacional;
- iv. Resolução CONAMA nº 398/2008: estabelece o conteúdo mínimo dos Planos de Emergência Individual (PEI). Revogou a CONAMA nº 293/2001, de maneira a ampliar o conteúdo anterior;
- v. Decreto nº 8.127/2013 (revogado): Institui o Plano Nacional de Contingência para Incidentes de Poluição por Óleo em Águas sob Jurisdição Nacional. Elaborado após o derramamento ocorrido no Golfo do México (substituído pelo Decreto nº 10.950/2022);
- vi. Resolução CONAMA nº 472/2015: normatiza o uso de dispersantes químicos para ações de resposta a incidentes de poluição por óleo no mar. Revoga a CONAMA nº 269/2000;
- vii. Decreto nº 10.950/2022: dispõe sobre o Plano Nacional de Contingência para Incidentes de Poluição por Óleo em Águas sob Jurisdição Nacional (PNC). Revoga o Decreto nº 8.127/2013. Tem por objetivo fixar responsabilidades, estabelecer estrutura organizacional, diretrizes, procedimentos e ações para a execução do PNC. Elaborado



após o incidente de poluição por óleo de origem desconhecida que atingiu as praias do Nordeste em 2019/2020.

Destaca-se o fato de que muitos dos instrumentos legais existentes no Brasil foram elaborados e/ou alterados de maneira reativa a incidentes ocorridos que indicaram lacunas, tanto de responsabilidades como de diretrizes claras de como proceder em situações reais específicas. Na Figura 2 foi elaborada linha do tempo dos principais instrumentos legais em paralelo com os eventos nacionais e internacionais ocorridos.



Figura 2 – Linha do tempo da legislação em associação com os incidentes envolvendo vazamento com óleo.

## II.4 OUTROS INSTRUMENTOS DE GESTÃO

### Cartas SAO

A Lei do Óleo atribuiu ao Ministério do Meio Ambiente a responsabilidade de identificar, localizar e definir os limites das áreas ecologicamente sensíveis com relação à poluição causada por lançamento de óleo e outras substâncias nocivas ou perigosas em águas sob jurisdição nacional. Para o atendimento dessa demanda legal, o MMA instituiu as Cartas de Sensibilidade Ambiental a Derramamentos de Óleo (Cartas SAO). As cartas SAO têm como objetivo serem ferramentas e fonte de informação para o planejamento e implantação de ações de resposta quando ocorrerem vazamentos de óleo. Permitem, entre outros, a identificação de áreas prioritárias para proteção (e aquelas de sacrifício quando necessário), o direcionamento de equipes e equipamentos (MMA, 2023).

Essas cartas têm quatro grupos de informações principais no escopo do seu conteúdo: 1) Sensibilidade ambiental do litoral ao óleo; 2) Recursos biológicos sensíveis ao óleo existentes



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

na área da carta; 3) Atividades socioeconômicas que podem ser prejudicadas por derramamentos de óleo ou afetadas pelas ações de resposta; 4) Informações para a implementação de ações de resposta a derrames, como estradas de acesso à costa, aeroportos, rampas para barcos, padrões de circulação oceânica e costeira, fontes potenciais de poluição por óleo e derivados, entre outros (MMA, 2023).

#### PAE Fauna

O Plano Nacional de Ação de Emergência para Fauna Impactada por Óleo (PAE-Fauna) foi elaborado pelo IBAMA em 2017 sendo constituído por três documentos: 1) Manual de Boas Práticas, tem por objetivo de estabelecer procedimentos a serem adotados no manejo de animais oleados resgatados e estabelecer as estruturas necessárias aos centros utilizados durante a resposta a um incidente; 2) Mapeamento Ambiental para Resposta à Emergência no Mar (Marem) é um banco de dados com informações sobre o litoral brasileiro capazes de contribuir na gestão de respostas a acidentes ambientais envolvendo óleo, e 3) Plano de Fauna Oleada do IBAMA, que tem por objetivo a organização interna do órgão nos eventos envolvendo fauna oleada, nele consta a equipe especializada a ser acionada, o fluxo de comunicação com as instâncias do PNC e a organização interna do IBAMA para atuação em tais eventos (IBAMA, 2023b).

#### Programas/ações

Com o objetivo de obter informações adicionais sobre as ações/programas/projetos desenvolvidos pelos integrantes do PNC (Marinha do Brasil, ANP e IBAMA) sobre o enfrentamento de ocorrências de poluição por óleo no território brasileiro, foi feita busca nas páginas da internet dos três órgãos.

No site da Marinha do Brasil, existe uma lista de Ações e Programas, no entanto, não consta nenhum registro relacionado com monitoramento, prevenção e combate à poluição por óleo (MARINHA DO BRASIL, 2023d). Ao inserir palavras-chave da ferramenta “Buscar” do site, foram encontradas notícias ainda sobre os eventos de 2019/2020, e mais recentemente sobre a participação da entidade em exercícios simulados, sem maiores detalhamentos técnicos sobre a ocorrência dos mesmos.

No site da ANP as buscas foram ainda mais infrutíferas. Na lista de Publicações não foram encontradas informações sobre a existência que qualquer ação de planejamento relacionado à



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

prevenção e combate a acidentes ambientais envolvendo óleo. Foi feita pesquisa na ferramenta “O que você procura?” e da mesma forma não foram encontradas referências ao tema (ANP, 2023).

No site do IBAMA foi encontrado abundante material sobre a temática na ferramenta "O que você procura?", incluindo dados sobre: licenciamento ambiental da atividade petrolífera, ocorrência de vazamentos de óleo, aplicação de multas, documentos relacionados ao PAE-Fauna, referências ao arcabouço legislativo, incluindo o Decreto nº 10.950, de 27 de janeiro de 2022. Consta também página criada para divulgar o material relacionado ao evento de 2019/2020 (IBAMA, 2023a).

Em nenhum dos sites foi encontrada referência a programas de monitoramento do mar territorial brasileiro com o uso de sensoriamento remoto.

## **II.5 A APLICAÇÃO DOS PRINCÍPIOS DO PNC NA PRÁTICA**

O incidente ocorrido em 2019/2020 foi o primeiro evento em escala nacional cuja aplicação do PNC se justificou, destaca-se que o acidente na Baía da Guanabara teve impacto local e ocorreu antes da regulamentação desse instrumento no Brasil. Já o acidente no Campo de Frade, embora de impacto ambiental significativo para o mar territorial brasileiro, por tanto de caráter nacional, não gerou acionamento do PNC. Talvez pelo fato de não ter atingido a costa e gerado cobertura midiática significativa.

No entanto, as análises jurídicas e técnicas sobre a implementação do instrumento em 2019/2020 são unânimes em afirmar que ocorreram atrasos e negligência do estado. Os meses da tragédia foram marcados por incertezas, dúvidas, falta de informações, de diretrizes, de coordenação e de liderança que impossibilitaram a adoção de respostas rápidas, agravadas pela ação fraca, descoordenada e demorada das instituições federais (ZACHARIAS et al. 2021; BRUM et al. 2020; SOARES et al. 2020; AZEVEDO, 2022; COSTA et al., 2020).

O atraso para a implantação do PNC e a inércia do governo pode ter contribuído para a amplificação dos impactos ecológicos, sociais e econômicos, fato evidenciado pela ausência de medidas de proteção para áreas vulneráveis, como as unidades de conservação, áreas de preservação ambiental, fozes de rios, mangues (SOARES et al., 2020; COSTA et al., 2020).



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

Destaca-se igualmente a falta de proteção aos voluntários envolvidos nas atividades de limpeza, que prestaram serviços incalculáveis para a sociedade brasileira sem nenhuma contrapartida estatal. Os resíduos contaminados com o óleo foram coletados manualmente sem equipamentos de proteção individual (COSTA et al., 2020). Não foram encontrados nos sites oficiais qualquer informação sobre as medidas adotadas na época e o acompanhamento do estado de saúde dos voluntários.

Lawand et al. (2021) ao realizar análise da responsabilidade jurídica relacionada ao vazamento de óleo, afirma que o Governo Federal não assumiu a liderança na gestão do incidente e, nem indicou quem seria o responsável por essa tarefa, o que dificultou resposta rápida, imediata e ordenada ao evento, indicando, dessa forma despreparo das instituições para o enfrentamento de situações de emergência. O governo brasileiro aceitou os riscos inerentes à inação, implicando na responsabilização e potenciais consequências legais das falhas e omissões ocorridas ao longo nos meses de gerenciamento do incidente (SOARES et al., 2020).

Quando, por fim, o Plano Nacional de Contingência foi implementado, apenas em 11/10/2019, foi de maneira inadequada, sem que houvesse um conjunto abrangente de diretrizes para organizar um plano de ação integrado que mitigasse a contaminação adicional do derramamento e aliviasse seus impactos (BRUM, 2020).

## **II.6 O USO DO SENSORIAMENTO REMOTO**

Um dos objetivos que precederam a elaboração do presente artigo era de realizar estudo comparativo dos trabalhos desenvolvidos em decorrência dos três eventos analisados que envolvessem o uso do sensoriamento remoto nas ações de resposta e acompanhamento dos eventos. No entanto, foi constatado, com surpresa, imensa lacuna dessas pesquisas científicas no Brasil. Foram realizadas buscas em diversas bases de conhecimentos disponíveis no portal de periódicos da Capes, principalmente na plataforma Web os Science, e até mesmo na página do Google Acadêmico (que engloba trabalhos não indexados) e os resultados encontrados foram escassos.

Baía da Guanabara:



De maneira geral, foram encontrados estudos escassos sobre o acidente e apenas 1 sobre sensoriamento remoto (BENTZ e MIRANDA, 2001). Tal fato pode se justificar pela localização conhecida da fonte de vazamento e dos locais atingidos, além da existência de insumos limitados na época do evento. O estudo de Bentz e Miranda (2001) utilizou 3 imagens, sendo 1 do satélite Landsat-5/TM (ótica) e 2 do Radarsat-1 (radar) para monitorar o local do vazamento e o deslocamento do óleo. Com o auxílio de SIG foi realizada classificação das imagens e mapeamento da área, no qual se constatou que 18 horas após o acidente o óleo estava espalhado em uma área de 33 km<sup>2</sup>, após 34 horas em 56 km<sup>2</sup>. A última imagem (adquirida em 26/01/2000) apresentou empecilhos para a sua interpretação, uma vez que o tempo decorrido dispersou o óleo e houve a interferência de outros fenômenos que dificultaram a análise (BENTZ e MIRANDA, 2001).

#### Campo de Frade:

O número de estudos encontrados sobre esse incidente é inexpressivo. A maior parte relacionados aos aspectos jurídicos. Nenhum específico sobre os impactos ambientais e apenas 1 relacionado ao uso de sensoriamento remoto, citando o evento como exemplo, não sendo o seu foco principal. Esse trabalho trata da identificação de feições oceanográficas na condição de *sun glint* em imagens do satélite MODIS e usa como um dos exemplos, imagens coletadas na época de ocorrência do vazamento no Campo de Frade (FREITAS et al., 2017).

A ausência de pesquisas científicas sobre o evento talvez se justifique pelo fato de o óleo vazado não ter atingido a costa. Embora o volume derramado tenha sido significativo, não ocorreu interesse midiático, o que pode ter refletido no interesse acadêmico.

#### Incidente 2019/2020:

Para esse evento foi encontrado maior número de estudos com a aplicação de metodologias de sensoriamento remoto (CONCEIÇÃO et al., 2021; FREIRE et al., 2022; LENTINI et al. 2022; NOBRE et al., 2022). Acredita-se, pelo número elevado de notas na mídia de trabalhos de universidades sobre o assunto, que tenham sido feitas numerosas tentativas de identificar o vazamento sem que houvesse resultados efetivos e, portanto, publicações científicas. Destaca-se que provavelmente o óleo se deslocou da fonte de vazamento até as praias por baixo da superfície do mar, na coluna d'água, o que impediu que o derramamento pudesse ser identificado por imagens de satélite e sobrevoos (LOURENÇO, 2020).





Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

As primeiras tentativas de uso do sensoriamento remoto para detecção da possível origem do vazamento de óleo que atingiu as praias nordestinas em 2019/2020 foram realizadas pelo INPE com o uso de imagens SAR oriundas do satélite Sentinel-1A/B, com auxílio de imagens óticas dos satélites Sentinel-2A/B e CBERS-4. Inicialmente foram analisadas 100 imagens (anteriores à primeira identificação do óleo) Sentinel-1 usando a metodologia de classificação *Unsupervised Semivariogram Textural* (USTC). Foram identificadas 24 feições escuras, sendo que 23 delas classificadas como óleo, sem, contudo, estarem associadas ao evento (NOBRE et al., 2022). Além disso, outras entidades também realizaram análise das mesmas imagens, de acesso público, como IBAMA, universidades e empresas privadas (NOBRE et al., 2022).

Cabe destacar que modelos matemáticos indicaram que o ponto de ocorrência do vazamento estava possivelmente localizado a mais de 400 km da costa brasileira, em local do oceano Atlântico sem cobertura satelital equipados com SAR (NOBRE et al., 2022), instrumento adequado para identificação de óleo no mar (MOURA et al., 2020), tendo o seu deslocamento ocorrido em subsuperfície devido a processos de intemperização, conforme se deslocava em direção ao Brasil, sendo indetectável nas imagens que existiam próximas da costa.

## II.7 CONCLUSÃO

Os estudos científicos sobre os acidentes envolvendo vazamentos de óleo no mar territorial brasileiro, analisados neste artigo, são escassos e descontinuados, não abrangem o acompanhamento de médio e longo prazo dos impactos ambientais, sociais e de saúde coletiva provocados pelos eventos. Aqueles envolvendo o uso do sensoriamento remoto são ainda mais exíguos. Esses têm sido usados de maneira esporádica e pontual no monitoramento e acompanhamento de vazamentos de óleo. Fato que ressalta a falta de imageamento satelitais do mar territorial brasileiro e a falta de incentivo/interesse de profissionais capacitados para a execução da tarefa. Embora o Brasil possua ampla e detalhada legislação, foi constatado que a letra da lei não se expressa na atuação estatal, ao longo dos 20 anos analisados no presente artigo, foi verificado o avanço significativo da lei que, contudo, não foi suficiente de evitar o caos ocorrido no evento de 2019/2020. Apesar do PNC já estivesse regulamentado na época da ocorrência desse incidente, sua implementação foi inadequada, não refletindo o potencial de



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

aprendizado que os eventos de 2000 e 2011 poderiam ter agregado para o poder público brasileiro. Tal ocorrido pode se justificar pela falta de continuidade de projetos, pela inexistência de memória institucional, pela falta de publicidade das ações pretéritas. O presente estudo identificou ainda a ausência de informações de acesso público sobre a atuação das instituições federais envolvidas nas ações de resposta aos eventos acidentais, principalmente dos dois mais antigos. Essa falta de memória institucional pode levar os pesquisadores e interessados no assunto ao entendimento de que exista inação do poder público. Entendimento esse que pode ser equivocado, contudo, justificado pela falta de transparência da divulgação da informação.

## REFERÊNCIAS

ACSELRAD, H.; MELLO, C. D. A. Conflito social e risco ambiental: o caso de um vazamento de óleo na Baía de Guanabara. In: ALIMONDA, H. (Org.). *Ecología Política. Naturaleza, Sociedad y Utopía*. Buenos Aires: CLACSO, 2002. p. 293-317.

AGÊNCIA NACIONAL DO PETRÓLEO, GÁS NATURAL E BIOCOMBUSTÍVEIS - ANP. *Investigação do incidente de vazamento de petróleo no Campo de Frade: Relatório final*. Jul. 2012. Disponível em: [https://www.gov.br/anp/pt-br/assuntos/exploracao-e-producao-de-oleo-e-gas/seguranca-operacional-e-meio-ambiente/incidentes/relatorios-de-investigacao-de-incidentes-1/arquivos-relatorios-de-investigacao-de-incidentes/campo-de-frade/relatorio-frade-i\\_final.pdf](https://www.gov.br/anp/pt-br/assuntos/exploracao-e-producao-de-oleo-e-gas/seguranca-operacional-e-meio-ambiente/incidentes/relatorios-de-investigacao-de-incidentes-1/arquivos-relatorios-de-investigacao-de-incidentes/campo-de-frade/relatorio-frade-i_final.pdf). Acesso em: 14 jan. 2023.

AGÊNCIA NACIONAL DO PETRÓLEO, GÁS NATURAL E BIOCOMBUSTÍVEIS - ANP. *Publicações*. Disponível em: <https://www.gov.br/anp/pt-br/centrais-de-conteudo/publicacoes>. Acesso em: 03 mar. 2023.

AZEVEDO, A. K.; VIEIRA, F. A.; GUEDES-SANTOS, J.; GAIA, J. A.; PINHEIRO, B. R., BRAGAGNOLO, C.; CORREIA, R.A.; LADLE, R. J.; MALHADO, A. A big data approach to identify the loss of coastal cultural ecosystem services caused by the 2019 Brazilian oil spill disaster. *Anais da Academia Brasileira de Ciências*, v. 94., p. e20210397, 2022. DOI: 10.1590/0001-3765202220210397

BENTZ, C.; DE MIRANDA, F. P. Application of remote sensing data for oil spill monitoring in the Guanabara Bay, Rio de Janeiro, Brazil. In: *IGARSS 2001. Scanning the Present and Resolving the Future*. IEEE 2001 International Geoscience and Remote Sensing Symposium (Cat. No. 01CH37217), 2001, Sydney, Australia, *Proceeding...* IEEE, 2001, p. 333-335. DOI: 10.1109/IGARSS.2001.976149



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

BRUM, H. D.; CAMPOS-SILVA, J. V.; OLIVEIRA, E. G. Brazil oil spill response: Government inaction. *Science*, v. 367, n. 6474, p. 155-156, 2020. DOI: 10.1126/science.aba0369

CAMPOS, I. Z. A. A atuação do tribunal marítimo em caso de poluição ambiental: responsabilidade administrativa marítima ambiental. *Direito e Desenvolvimento*, v. 7, n. 2, p. 171-188, 2016. DOI: 10.26843/direitoedesenvolvimento.v7i2.323

CONCEIÇÃO, M. R. A.; DE MENDONÇA, L. F. F.; LENTINI, C. A. D.; DA CUNHA LIMA, A. T.; LOPES, J. M., DE VASCONCELOS, R. N.; GOUVEIA, M. B.; e PORSANI, M. J. SAR oil Spill detection system through random forest classifiers. *Remote Sensing*, v. 13, n. 11, p. 2044, 2021. DOI: 10.3390/rs13112044

COSTA, W. C. L.; SILVA, A. S. A Responsabilidade Civil Estatal Frente aos Desastres Ambientais: O Óleo no Litoral do Nordeste. In: DA SILVEIRA, A. F.; MAMED, D. DE O.; FERREIRA, H. S.; DA SILVA, L. A. L.; CALEIRO, M. M. (Org.). *Natureza, Povos e Sociedade de Risco*. v. IV., Curitiba, PR: CEPEDIS, 2021. cap. 1, p. 7- 33.

DIAS NETO, J. *Análise do Seguro-Desemprego do Pescador Artesanal e de Possíveis Benefícios para a Gestão Pesqueira*. Brasília: IBAMA, 2017. 120 p.

FREIRE, N. C.; CAMPOS, L. H. R.; QUEIROZ, V.; SOUZA, L. B.; SILVA, M. C. Multispectral Remote Sensing for mapping the areas affected by the techno-industrial disaster of the oil spill on Brazilian beaches. *Anais da Academia Brasileira de Ciências*, v. 94, suppl. 2, p. e20210308, 2022. DOI: 10.1590/0001-3765202220210308

FREITAS, L. B.; KAMPEL, M.; LORENZZETTI, J. A. Feições Oceanográficas em Imagens MODIS na Condição de Sun glint: Exemplos para a Costa Sudeste Brasileira. *Revista Brasileira de Meteorologia*, v. 32, p. 321-41, 2017. DOI: 10.1590/0102-77863230014

INSTITUTO BRASILEIRO DO MEIO AMBIENTE E DOS RECURSOS NATURAIS RENOVÁVEIS – IBAMA. *Manchas de Óleo Litoral Brasileiro*. 2023a. Disponível em: <http://www.ibama.gov.br/manchasdeoleo#>. Acesso em: 02 mar. 2023.

INSTITUTO BRASILEIRO DO MEIO AMBIENTE E DOS RECURSOS NATURAIS RENOVÁVEIS - IBAMA. *Plano Nacional de Ação de Emergência para Fauna Impactada por Óleo (PAE-Fauna)*. 2023b. Disponível em: <https://www.gov.br/ibama/pt-br/assuntos/notas/2020/plano-nacional-de-acao-de-emergencia-para-fauna-impactada-por-oleo-pae-fauna>. Acesso em: 02 mar. 2023.



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

INSTITUTO DE PESQUISA ECONÔMICA APLICADA - IPEA. *Extrator de Dados Ipea*. Disponível em: <http://www.ipea.gov.br/extrator/simt.html>. Acessado em: 05 nov. 2019.

LAWAND, A.; DE ALMEIDA SILVA, C. D.; DE OLIVEIRA, L. P. F. Derramamento de óleo no nordeste brasileiro: Responsabilização e desdobramentos. *Revista de Direito e Negócios Internacionais da Maritime Law Academy - International Law and Business Review*, v. 1, n. 1, p. 84-113, 2021.

LENTINI, C. A. D.; MENDONÇA, L. F. F.; CONCEICAO, M. R. A.; LIMA, A. T.; VASCONCELOS, R. N.; e PORSANI, M. J. Comparison between oil spill images and look-alikes: an evaluation of SAR-derived observations of the 2019 oil spill incident along Brazilian waters. *Anais da Academia Brasileira de Ciências*, v. 94, suppl. 2, p. e20211207, 2022. DOI: 10.1590/0001-3765202220211207

LOURENÇO, R. A.; COMBI, T.; DA ROSA ALEXANDRE, M.; SASAKI, S. T.; ZANARDI-LAMARDO, E.; e YOGUI, G. T. Mysterious oil spill along Brazil's northeast and southeast seaboard (2019–2020): Trying to find answers and filling data gaps. *Marine Pollution Bulletin*, v. 156, p. 111219, 2020. DOI: 10.1016/j.marpolbul.2020.111219

MACIEL-SOUZA, M. D. C.; MACRAE, A.; VOLPON, A. G. T.; FERREIRA, P. S.; e MENDONÇA-HAGLER, L. C. Chemical and microbiological characterization of mangrove sediments after a large oil-spill in Guanabara Bay-RJ-Brazil. *Brazilian Journal of Microbiology*, v. 37, p. 262-266, 2006. DOI: 10.1590/S1517-83822006000300013

\_\_\_\_\_. *Marpol*. 2023a. Disponível em: <https://www.ccaimo.mar.mil.br/ccaimo/marpol>. Acesso em: 08 mar. 2023.

\_\_\_\_\_. *CLC*. 2023b. Disponível em: <https://www.ccaimo.mar.mil.br/ccaimo/clc>. Acesso em: 08 mar. 2023.

\_\_\_\_\_. *OPRC*. 2023c. Disponível em: <https://www.ccaimo.mar.mil.br/ccaimo/codigos-e-convencoes/convencoes/oprc>. Acesso em: 08 mar. 2023.

MARINHA DO BRASIL. *Ações e Programas*. 2023d. Disponível em: <https://www.marinha.mil.br/acoes-e-programas>. Acesso em: 08 mar. 2023.

MINISTÉRIO DO MEIO AMBIENTE - MMA. *Cartas de Sensibilidade ao Óleo*. Disponível em: <https://antigo.mma.gov.br/seguranca-quimica/cartas-de-sensibilidade-ao-oleo.html>. Acesso em: 02 mar. 2023.

MONTEIRO, A.G. *Metodologia de avaliação de custos ambientais provocados por vazamento de óleo: o estudo de caso do complexo REDUC-DTSE*. 2003. 271 f. Tese (Doutorado em



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

Planejamento Energético e Ambiental) - Programa de Pós-graduação em Engenharia, Universidade Federal do Rio de Janeiro. Rio de Janeiro, 2003.

MOURA, N.V.A.; DE CARVALHO JÚNIOR, O.A.; TRANCOSO GOMES, R.A.; FONTES GUIMARÃES, R. Revisão sobre o uso de sensoriamento remoto na detecção de vazamentos de óleo no mar. *Caminhos de Geografia*, v. 21, n. 75, p. 214–224, 2020. DOI: 10.14393/RCG217551341

NOBRE, P.; LEMOS, A. T.; GIAROLLA, E.; CAMAYO, R.; NAMIKAWA, L.; KAMPEL, M.; RUDORFF, N.; BEZERRA, D. X.; LORENZZETTI, J.; GOMES, J.; SILVA JR, M. B. DA; LAGE, C. P. M.; PAES, R. L.; BEISL, C.; LOBÃO, M. M.; BIGNELLI, P. A.; MOURA, N. DE; GALVÃO, W. S.; POLITO, P. S. The 2019 northeast Brazil oil spill: scenarios. *Anais da Academia Brasileira de Ciências*, v. 94. suppl. 2, p. e20210391, 2022. DOI: 10.1590/0001-3765202220210391

PEDROSA, L. F. *Análise dos mecanismos de planejamento e resposta para incidentes com derramamento de óleo no mar: uma proposta de ação*. 2012. 118 f. Dissertação (Mestrado em Planejamento Energético) - Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa de Engenharia (COPPE), Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2012.

PENA, P. G. L.; NORTHCROSS, A. L.; LIMA, M. A. G. D.; RÊGO, R. D. C. F. Derramamento de óleo bruto na costa brasileira em 2019: emergência em saúde pública em questão. *Cadernos de Saúde Pública*, v. 36, n. 2, p. e00231019, 2020. DOI: 10.1590/0102-311X00231019

SENADO FEDERAL. *Proposta de Emenda à Constituição nº 184, de 2019*. Disponível em: <https://www25.senado.leg.br/web/atividade/materias/-/materia/139657>. Acesso em: 03 mar. 2023.

SOARES, M. DE O.; TEIXEIRA, C. E. P.; BEZERRA, L. E. A.; PAIVA, S. V.; TAVARES, T. C. L.; GARCIA, T. M.; DE ARAÚJO, J. T.; CAMPOS, C. C.; FERREIRA, S. M. C.; MATTHEWS-CASCON, H.; FROTA, A.; MONT'ALVERNE, T. C. F.; SILVA, S. T.; RABELO, E. F.; BARROSO, C. X.; FREITAS, J. E. P. DE; MELO JÚNIOR, M. DE; CAMPELO, R. P. DE S.; SANTANA, C. S. DE; CARNEIRO, P.B. DE M.; CAVALCANTE, R. M. Oil spill in South Atlantic (Brazil): Environmental and governmental disaster. *Marine Policy*, v. 115, p. 103879, 2020. DOI: 10.1016/j.marpol.2020.103879

SOUSA, L. G. R.; DE MIRANDA, A. C.; DE MEDEIROS, H. B. Impacto ambiental e socioeconômico do derramamento de óleo na Baía de Guanabara. *Periódico Eletrônico Fórum Ambiental da Alta Paulista*, v. 9, n. 2, p. 94-108, 2013. DOI: 10.17271/19800827922013633



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

ZACHARIAS, D. C.; GAMA, C. M.; FORNARO, A. Mysterious oil spill on Brazilian coast: Analysis and estimates. *Marine Pollution Bulletin*, v. 165, p. 112125, 2021. DOI: 10.1016/j.marpolbul.2021.112125



## CAPÍTULO III

### REVISÃO SOBRE O USO DE SENSORIAMENTO REMOTO NA DETECÇÃO DE VAZAMENTOS DE ÓLEO NO MAR

#### RESUMO

Vazamentos de óleo no mar são de grande preocupação pública por representarem riscos para o meio ambiente e para a população costeira. Com o crescimento da exploração do petróleo e da movimentação de navios aumenta a possibilidade de acidentes, nesse contexto o sensoriamento remoto é usado como ferramenta indispensável para a detecção e monitoramento das manchas de óleo na superfície marítima. O presente trabalho traz uma revisão das pesquisas recentes desenvolvidas na área, que sobretudo visam melhorar a acurácia da detecção e classificação das manchas com potencial de serem derramamento de óleo. O Radar de Abertura Sintética (SAR) destaca-se como o sensor mais usado, por ser eficiente mesmo com a presença de nuvens e no período noturno. O desafio atual é a necessidade de criar metodologias eficientes na distinção de manchas de óleo de outras feições escuras que aparecem na imagem de radar formadas por fenômenos diversos que podem gerar falsos-positivo.

**Palavras-chave:** Radar; Classificação; Monitoramento.

#### REVIEW OF REMOTE SENSE USE FOR OIL SPILL DETECTION IN THE SEA

#### ABSTRACT

Oil spills at sea are a major public concern as they represent risks to environment and coastal population. The growth of oil exploration and ship movement increases the possibility of accidents, in this context remote sensing is used as an indispensable tool for the detection and monitoring of oil slicks on the sea surface. The present work presents a review of the recent research developed in the area, which mainly aims to improve the accuracy of detection and classification of oil spill. Synthetic Aperture Radar (SAR) stands out as the most used sensor, being efficient even in the presence of clouds and at night. The current challenge is the need to create efficient



methodologies in distinguishing oil slicks from other dark features that appear in the radar image formed by various phenomena that can generate lookalikes.

**Keywords:** Radar; Classification; Monitoring.

---

### III.1 INTRODUÇÃO

Anualmente milhares de toneladas de óleo são derramadas nos oceanos, seja por causas antropogênicas, seja por causas naturais. Os derramamentos provocados pela ação humana podem ser intencionais ou acidentais, envolvendo tanques de embarcações, ruptura de dutos e mal funcionamento de plataformas de exploração de petróleo. Os vazamentos de causas naturais têm origem em rupturas ocorridas no fundo marinho (BREKKE e SOLBERG, 2005b; PISANO et al., 2016).

Com o aumento da exploração comercial do petróleo e da movimentação de navios é crescente o registro de ocorrência de vazamentos (YU, 2007), especialmente aqueles oriundos de descargas ilegais e intencionais de, por exemplo, água oleosa oriunda das lavagens de tanques, porões e conveses de embarcações e da liberação de água de produção de plataformas de petróleo contendo teor de óleo acima da especificação legal (MISRA e BALAJI, 2017). Adicionalmente, a identificação, prevenção e atendimento a emergências envolvendo vazamentos de óleo ocorridos no mar, são de preocupação pública uma vez que apresentam grande potencial de danos letais aos ecossistemas marítimos e costeiros (ESPEDAL e JOHANNESSEN, 2000; FISCELLA et al., 2000; SINGHA et al., 2013; FUSTES et al., 2014; ZHANG et al., 2014; ABASCAL et al., 2017; ALPERS et al., 2017). Ressalta-se que no presente trabalho é usada a palavra “óleo” para qualquer forma de hidrocarboneto (petróleo e seus derivados) oriundo da exploração de petróleo ou da movimentação de navios, provocados intencionalmente ou por acidentes, conforme conceituação da Lei nº 9.966/2000 (BRASIL, 2019).

Portanto, torna-se imprescindível a existência de ferramentas que contribuam para a fiscalização dos vazamentos irregulares e para assegurar o cumprimento das regulamentações nacionais e internacionais para o controle das atividades e proteção ambiental (ESPEDAL e JOHANNESSEN, 2000; SINGHA et al., 2013). Para o atendimento eficiente a um acidente dessa natureza é essencial que as ações de resposta sejam adotadas de maneira rápida e que a detecção ocorra o mais cedo possível (KERAMITSOLOU et al., 2006). Nesse contexto, o sensoriamento remoto é de grande importância para a proteção ambiental das áreas costeiras e primordial para a vigilância marítima uma vez que propicia a identificação precoce de acidentes envolvendo o vazamento de óleo, além de ser capaz de identificar eventos em áreas remotas e de difícil acesso (SINGHA et al., 2013; ZHANG et al., 2014). Fingas e Brown (2014; 2018) em revisão sobre o assunto, indicam o uso do sensoriamento remoto como ferramenta eficiente na gestão ambiental de um vazamento de óleo em diferentes etapas: mapeamento dos vazamentos, vigilância e detecção, produção de provas para processos judiciais, fiscalização do cumprimento de leis sobre descarga de navios, orientação para tomada de medidas de controle do vazamento e determinação da trajetória da mancha de óleo.





Os principais métodos de sensoriamento remoto para a detecção de vazamentos de óleo estão baseados no uso de sensores óticos e de radar, sendo que o SAR (Synthetic Aperture Radar) possui maior utilização devido a sua capacidade de funcionamento sob qualquer condição atmosférica e de luminosidade, incluindo durante a noite (PISANO, et al.; 2016). Segundo Garcia-Pineda et al. (2013), o uso de radar apresenta maiores vantagens para o monitoramento de vazamento de óleo nos oceanos, uma vez que é um sistema ativo, ao contrário dos sensores óticos que precisam de iluminação solar e são limitados quando há a presença de nuvens ou baixa luminosidade.

O presente estudo tem por objetivo apresentar as metodologias de sensoriamento remoto recentemente desenvolvidas e aplicadas no mundo para a detecção de óleo na superfície do mar, com destaque para aquelas que utilizam imagens SAR, uma vez que estas são amplamente usadas para este fim e mostram ser mais eficientes (GARCIA-PINEDA et al., 2013).

### **III.2 SENSORES USADOS PARA DETECTAR MANCHAS DE ÓLEO E SUAS CARACTERÍSTICAS**

Atualmente diversas técnicas de sensoriamento remoto são usadas para a detecção dos vazamentos de óleo no mar, especialmente por permitirem o monitoramento de áreas grandes em relativo curto espaço de tempo, em contraste com o monitoramento visual realizado por aeronaves e embarcações que têm elevados custos e área de abrangência limitada. Os sensores mais utilizados são Side Looking Airborne Radar (SLAR), Infravermelho (IR), Ultravioleta (UV), laser fluorenses (presentes sobretudo em aeronaves) e, Synthetic Aperture Radar (SAR) e sensores óticos, presentes em diversas plataformas de satélites e aeronaves (ESPEDAL e JOHANNESSEN, 2000; FINGAS e BROWN, 2014).

Fingas e Brown (2014; 2018) apresentam as propriedades óticas do óleo e suas características específicas de comportamento no uso de diversos sensores. Caracterizam os sensores visíveis, infravermelho, NIR, ultravioleta, laser fluorosensores, micro-ondas (passivos e radares), apresentando para este o detalhamento mínimo do processamento. Considerando o uso de sensores que operam na faixa do visível, os autores afirmam que o óleo possui refletância maior que a água, mas sem apresentar características específicas quanto a absorção e reflexão, não existindo, portanto, meios de identificar positivamente o óleo da água com esses sensores. Especificamente sobre os sensores presentes em satélites, os autores afirmam que existe a desvantagem de serem imagens obtidas com intervalos de tempo longos e que demandam longo tempo de processamento, além de serem limitados quando há a presença de nuvens e sofrerem interferência do reflexo do sol em determinadas partes das imagens. Brekke e Solberg (2005b) também afirmam que as condições atmosféricas são limitadoras para o uso de sensores que operam na faixa do visível.

Sensores que operam na faixa do infravermelho baseiam-se na diferença de temperatura entre a água e o óleo. O óleo absorve parte da radiação solar e reemite parte dela como energia termal, dessa maneira, as manchas de óleo grossas aparecem nas imagens como quente, as de espessura intermediária aparecem mais frias, enquanto as manchas finas não serão detectadas. No entanto, durante a noite camadas grossas de óleo podem ser detectadas como frias uma vez que esfriam mais rápido que a água ao redor. Esses sensores possuem limitações,



principalmente quando o óleo forma emulsão com a água (BREKKE e SOLBERG, 2005b; FINGAS e BROWN, 2014).

Os sensores ultravioletas têm o seu funcionamento decorrente da elevada reflexividade do óleo nessa faixa. Esses instrumentos são capazes de detectar óleo até em finas camadas, contudo, têm como limitação o fato de não poderem ser usados a noite e por gerar falso-positivos em manchas causadas pelo vento, por reflexos do sol e por material biogênico, não sendo uma ferramenta muito utilizada (BREKKE e SOLBERG, 2005b; FINGAS e BROWN, 2014).

Outro tipo de sensor remoto usado para identificar a presença de óleo na água faz uso de laser fluorosensores. São sensores que se baseiam no fato de certos componentes aromáticos do óleo se tornarem fluorescentes, sobretudo ao receberem luzes ultravioletas. São capazes de detectar o óleo presente na superfície da água e também contido na coluna d'água até 2 metros de profundidade. Esses sensores são indicados para a detecção do óleo uma vez que a fluorescência do óleo apresenta comprimento de onda bastante específico a ponto de não ser confundido com outras substâncias presentes na água (FINGAS e BROWN, 2014).

Sensores hiperespectrais têm potencial para identificação detalhada de materiais e melhor estimativa de sua abundância, uma vez que permite o detalhamento físico-químico da substância presente na superfície imageada. Seus diferentes comprimentos de onda podem ser usados para reconhecimento da assinatura espectral de diferentes tipos de óleo, também pode ser usado para distinção de manchas formadas por outros materiais que tenham aspecto similar (BREKKE e SOLBERG, 2005b).

Sensores que operam na faixa das micro-ondas são aqueles mais comumente usados para a detecção de poluição de óleo, principalmente sensores ativos como os radares. São preferíveis, comparados aos sensores óticos, por serem eficientes em quaisquer condições de tempo e luminosidade. Os mais comuns são o SLAR (Side-Looking Airborne Radar) que tem como desvantagem ser caro e estar presente em aeronaves que têm área de cobertura limitada, e o Synthetic Aperture Radar (SAR). O uso de SAR tem a vantagem de permitir o monitoramento em qualquer condição de luminosidade e climática (ESPEDAL e JOHANNESSEN, 2000; BREKKE e SOLBERG, 2005b; FINGAS e BROWN, 2014).

Sensores MWR (microwave radiometer) são sensores passivos que captam as micro-ondas refletidas pela superfície, oriundas da radiação do espaço. São usados com maior frequência para medição da espessura da mancha de óleo e cálculo do volume vazado (BREKKE e SOLBERG, 2005b; FINGAS e BROWN, 2014).

Destaca-se que nenhum dos sensores pode individualmente fornecer todas as informações necessárias para o gerenciamento de um incidente envolvendo vazamento de óleo, cada um apresenta vantagens e desvantagens, tendo aplicações específicas. Sensores presentes em satélites, como alguns SAR, apresentam como vantagem o fato de terem baixos custos, por outro lado, têm baixa resolução temporal e espacial, quando comparados aos sensores presentes em aeronaves (GARCIA-PINEDA et al., 2013).

Segundo Brekke e Solberg (2005b), o SAR é o mais eficiente sensor satelital para a detecção de óleo, embora não tenha capacidade para detectar a espessura da mancha e o tipo de óleo. Adicionalmente, afirma que o uso do SAR apresenta como desvantagem o fato de não distinguir



manchas formadas por óleo, daquelas formadas por outros de fenômenos que também geram na imagem manchas escuras, podendo gerar falso-positivos.

### **III.3 CARACTERÍSTICAS DO SAR E SUA APLICAÇÃO NA IDENTIFICAÇÃO DE MANCHAS DE ÓLEO**

O SAR é um sensor ativo que emite micro-ondas em intervalo de frequência que inclui a banda X (8 a 12 GHz, 2,50 a 4 cm), banda C (4 a 8 GHz, 4 a 8 cm) e banda L (1 a 2 GHz, 15 a 30 cm). Por meio das micro-ondas é detectado o alcance, a velocidade e outras características dos objetos remotos (GARCIA-PINEDA et al., 2013). Assim, o SAR emite micro-ondas e grava os sinais refletidos pelos objetos alvos (ZHANG et al., 2014).

Três componentes principais dominam o retorno de energia da superfície da Terra a um satélite equipado com SAR: 1) a geometria entre as posições relativas do satélite e da imagem (ou seja, espectros direcionais de ondas e ângulos de incidência do feixe); 2) rugosidade; e 3) as propriedades dielétricas dos materiais da superfície (GARCIA-PINEDA et al., 2013).

As propriedades de dispersão de um material dependem da polarização do sinal do radar tanto de entrada como de saída, tendo sido demonstrado por alguns estudos que para a identificação dos vazamentos de óleo a configuração mais adequada para o SAR é a VV (propagação vertical da onda na emissão e na transmissão e na recepção do sinal) (BREKKE e SOLBERG, 2005b; FINGAS e BROWN, 2014).

Nos trabalhos de sensoriamento remoto desenvolvidos em áreas marítimas o mecanismo de atuação do SAR ocorre a partir da interação das micro-ondas com as ondas capilares formadas na superfície da água (ZHANG et al., 2014), conforme detalhado no próximo item.

### **III.4 CARACTERÍSTICAS DAS MANCHAS DE ÓLEO E FALSO-POSITIVOS PRESENTES NAS IMAGENS SAR**

Em condições normais, a superfície do mar aparece nas imagens de radar de maneira brilhante, uma vez que as ondas capilares, formadas pela incidência do vento na água, refletem a energia emitida pelo radar. Contudo, a existência de óleo no mar ameniza o efeito dessas ondas, uma vez que torna a superfície mais plana e reduz o coeficiente de retroespalhamento do radar, dessa forma a presença de óleo na água aparece na imagem como manchas escuras que contrastam com a água ao redor sem a presença de óleo (FISCELLA et al., 2000; FINGAS e BROWN, 2014; PISANO et al., 2016; ALPERS et al., 2017).

No entanto, diversas outras causas podem produzir o mesmo fenômeno na superfície da água, gerando, da mesma forma, manchas escuras nas imagens (BREKKE e SOLBERG, 2005b; MARGHANY, 2001; ZHANG et al., 2014). Os denominados falso-positivos (lookalike) podem ocorrer em decorrência de fenômenos naturais, tais como: óleos naturais, zonas de cisalhamento do relevo marítimo, células de chuva, presença de água doce próximas à foz de rios, áreas de calmaria de vento, sombras atrás de porções de terra e de estruturas, camadas de algas abaixo da superfície da água que fazem com que a água acima se torne calma, presença de gelo, substâncias biogênicas (produzidas, por exemplo, por fitoplâncton, espermatozoides de baleias



e peixes ou substâncias oriundas de sua decomposição), áreas abrigadas, água quente que muda a estabilidade da interface ar/mar, fluxo divergente associado a ondas internas ou fluxo de maré sobre bancos de areia e água oriunda de tempestade que flui da terra para o mar. Falso-positivos também surgem em decorrência da ação humana como: ocorrência de turbulência na água encontrada após a passagem de navios, vazamentos de água doce de navios, águas residuais oriundas de plantas industriais ou áreas urbanas (sobretudo esgoto), derramamento de óleo durante limpeza de tanque de navios que transportam óleo vegetal ou óleo de peixe oriundo de navios de pesca (ESPEDAL e JOHANNESSEN, 2000; BREKKE e SOLBERG, 2005b; TOPOUZELIS et al., 2007; FINGAS e BROWN, 2014; ZHANG et al., 2014; PISANO et al., 2016; ALPERS et al., 2017).

Dessa forma, considerando o elevado número de fenômenos na superfície marítima que podem gerar o aparecimento de manchas escuras em imagens de radar, é essencial o desenvolvimento de metodologias que diferenciem uma feição da outra, sendo esse o principal desafio a ser superado (FINGAS e BROWN, 2014; ALPERS et al., 2017). Segundo estudo de Fingas e Brown (2014) foram detectados como falso-positivo 20% das manchas registradas como óleo.

Outro fator limitante para a confirmação de óleo diz respeito à velocidade adequada do vento, havendo variação da faixa ideal entre as pesquisas analisadas: (a) de 3 m/s até 8 m/s (FINGAS e BROWN, 2014); (b) de 2m/s até 10 m/s (FISCELLA et al., 2000); (c) detecção possível entre 2 e 12 m/s e intervalo otimizado entre 5 e 6 m/s (JONES, 2001). Em condições onde a velocidade do vento é baixa (inferior a 2 m/s), a detecção de óleo através de radar não é possível devido à redução e aplainamento das ondas capilares (PISANO et al., 2016). Em contraste, a elevada velocidade do vento intensifica a formação de ondas de maneira que camadas de óleo, mesmo as espessas, não teriam condições de amenizar o efeito de ondas intensas. Adicionalmente, o óleo presente na água submetida a ventos intensos sofre dispersão mecânica, desaparecendo rapidamente da superfície (FISCELLA et al., 2000; BENTZ et al., 2005; ZHANG et al., 2014; PISANO et al., 2016).

Diante das diversas condições que podem gerar falso-positivos é necessário observar durante a análise das imagens, sobretudo nas abordagens manuais, a forma da mancha como fator que contribui para a distinção entre manchas de óleo e outros fenômenos, considerando principalmente as características das bordas, a extensão e a área ao redor. As manchas de óleo tendem a ter as bordas bem definidas e o formato alongado e retilíneo ou levemente curvado (TOPOUZELIS, 2008). Guo e Zhang (2014) e Topouzelis e Singha (2016) sintetizam como o principal problema na detecção de vazamentos de óleo, justamente a necessidade de fazer a discriminação entre os vazamentos reais e os falso-positivos.

### **III.5 PESQUISAS PARA IDENTIFICAÇÃO DE MANCHAS DE ÓLEO EM IMAGENS SAR**

Duas formas de abordagem metodológica são usadas para a detecção de vazamentos de óleo em imagens SAR: a manual e a semiautomática e/ou inteiramente automática. A primeira abordagem é a mais popular, pouco complexa e de fácil reprodução, sendo dependente da experiência do analista em saber distinguir, principalmente através da forma e da análise dos



arredores, um vazamento real de um falso-positivo (TOPOUZELIS, 2008; MISRA e BALAJI, 2017). Adicionalmente, o analista deve considerar informações da área da imagem como velocidade do vento, correntes marítimas e períodos de insurgência de algas (TOPOUZELIS, 2008).

A abordagem semiautomática e/ou totalmente automática é considerada mais complexa e difícil de ser reproduzida, demandando conhecimento dos padrões das imagens e das teorias de classificação (TOPOUZELIS, 2008). Para o processamento das imagens SAR, nessa abordagem, são adotadas fases essenciais (TOPOUZELIS, 2008; LANG et al., 2017).

1. Detecção e isolamento de todas as formações escuras apresentadas na imagem. Esta etapa é resultado do processamento de limiarização e segmentação, visa destacar as feições com potencial de serem vazamentos de óleo.
2. Extração de parâmetros estatísticos das manchas escuras. Onde é gerado um vetor com as características que descrevem quantitativamente as manchas. Estas características estão relacionadas com a geometria da formação (área, perímetro, forma das bordas), o comportamento físico (valor médio de retroespalhamento) e contexto da mancha na imagem (distância de navios, plataformas e linha de costa).
3. Teste dos valores extraídos em relação a valores pré-definidos, que caracterizam os vazamentos de óleo e as manchas formadas por outros fenômenos. Esses valores são geralmente determinados por meio de considerações fenomenológicas e avaliações estatísticas.
4. Classificação das manchas escuras. Nessa etapa ocorre a distinção entre vazamentos de óleo e falso-positivos. Vários classificadores são usados, podendo ser usadas diversas abordagens estatísticas através do cálculo de probabilidades como através de redes neurais, lógica difusa, etc. (TOPOUZELIS, 2008; LANG et al., 2017).

Zhang et al. (2014) estabelecem, de maneira similar, a estrutura padrão dos algoritmos, destacando a importância da etapa de pré-processamento como procedimento fundamental para melhorar a precisão da detecção de óleo. Seguindo essa linha de ação, Espedal e Johannessen (2000) apresentam a metodologia usada pelo Nansen Environmental and Remote Sensing Center (NERSC) da Noruega para distinguir manchas de vazamentos naturais inofensivos, daquelas provocadas pela ação humana, tendo sido desenvolvido algoritmo supervisionado que contém os seguintes passos: processamento inicial das imagens; análise direta (considerando a fonte do vazamento caso esteja visível, forma, tamanho e dimensão, textura, amortecimentos e gradientes); análise contextual (considerando informações sobre ventos, fontes de poluição, chuvas, temperatura/estação, presença de gelo e a topografia do fundo oceânico); modelagem do comportamento da mancha (o modelo usado deve ser baseado em condições ambientais relevantes para o vazamento em estudo); estabelecimento de conclusões com base na combinação de resultados. Os autores concluem que o algoritmo fornece um procedimento padrão a ser seguido e garante que os mesmos critérios sejam aplicados cada vez que uma mancha é analisada.



Em trabalho sobre os desafios e dificuldades na classificação de manchas escuras, Alpers et al. (2017) destacam a necessidade de que os algoritmos de detecção de vazamentos de óleo sejam melhorados consideravelmente, incluindo informações sobre: 1) a distribuição de clorofila-a (indicando a presença provável de manchas biogênicas); 2) a localização das plataformas de petróleo e óleo; 3) a localização das correntes marítimas superficiais; 4) informações sobre a condição dos ventos próximos da superfície do mar; 5) a localização dos bancos de areia (que aparecem escuros nas imagens SAR); 6) a localização de frentes (limite entre duas massas de água com características distintas que muitas vezes se manifestam como linhas escuras em imagens SAR); 7) diferença entre a temperatura do ar e do mar; 8) as distribuições de células de chuva (usando imagens de radar meteorológico); e, o mais importante, 9) incluindo informações sobre o tráfego de navio.

Bentz et al. (2005) apresentam metodologia desenvolvida para o monitoramento ambiental de áreas costeiras e oceânicas com múltiplos sensores orbitais e afirmam ser necessário a análise do tamanho, forma, textura e contexto espacial das manchas escuras, provocadas pelo baixo retroespalhamento dos pulsos emitidos, visando a identificação do fenômeno que deu origem. Dessa forma, a metodologia desenvolvida cruza dados de temperatura da superfície da água, direção e velocidade do vento, presença de nuvens, forma da mancha e concentração de clorofila-a, para identificação da origem das manchas na imagem de radar.

Brekke e Solberg (2005a; 2008) propõem metodologia onde a estrutura do algoritmo é composta por: 1) detector de manchas escuras; 2) ferramenta de extração; e 3) classificador das manchas escuras. As autoras sugerem a introdução da regularização das matrizes de covariância para diminuir o número de falso-positivos e comparam o método de classificação Support Vector Machines (SVM) com o classificador estatístico regularizado. O estudo propõe procedimento de classificação em dois passos para a detecção de vazamentos de óleo em imagens SAR, consistindo em um classificador estatístico regularizado e uma estimativa de confiança automática das manchas detectadas. Essa combinação leva a um desempenho de classificação aceitável se o algoritmo for executado antes de verificação visual (com envio de aeronave/navio para confirmação do vazamento).

Fiscella et al. (2000) desenvolveram metodologia para distinção de manchas em imagens SAR, a partir do uso de informações estatísticas obtidas de acidentes anteriores com fontes conhecidas, baseada em características físicas e geométricas de manchas tanto de vazamentos quanto de feições naturais que podem representar falso-positivos. Para aplicação da metodologia inicialmente foram selecionadas somente imagens com a presença de manchas escuras, na sequência foram recortadas as cenas com as manchas (de forma manual ou automática), em seguida aplicada máscara para descartar as porções de terras e as manchas escuras de baixa relevância (aquelas muito grandes, com maior probabilidade de ser área de ventos, e as muito pequenas, que potencialmente representariam vazamentos insignificantes). Para a elaboração do algoritmo foram quantificadas informações sobre perímetro e área da mancha, média NRCS (Normalized Radar Cross-section) e fator de forma; a etapa posterior foi a classificação usando dois diferentes métodos: Mahalanobis e classificação de probabilidade composta, ambos com resultados semelhantes. No estudo foram usadas 80 amostras de vazamentos e 43 de falso-positivos. O método aplicado foi capaz de classificar 80% das



manchas corretamente e teve resultados similares de classificação feita por interpretação visual de imagens do mesmo grupo de manchas.

Garcia-Pineda et al. (2009) desenvolveram um algoritmo usando rede neural baseado na textura na superfície da água. A abordagem usou filtro para detecção de bordas, descritor de textura, coleção de informações e dados ambientais processados por redes neurais. Foram feitos processamentos em imagens que apresentavam diferentes condições ambientais. Nesse estudo foi encontrada como valor ideal de velocidade do vento para a identificação das manchas de óleo o intervalo de 3,5 a 7,0 m/s e o melhor ângulo de incidência para detecção na banda C é de 22° a 40°.

Visando compartilhar dados oriundos de pesquisas sobre o uso de imagens SAR para a detecção de manchas de óleo no mar, Fustes et al. (2014) apresentam uma ferramenta, denominada Sentinazos, criada para detecção de vazamentos de óleo em áreas costeiras, cujo processamento de dados acontece na “nuvem”, onde é possível a participação de usuários externos para o compartilhamento de informações e métodos dentro de uma estrutura integrada. Essa ferramenta permite que as imagens sejam pré-processadas, com calibração, filtragem e aplicação de projeção cartográfica. Para o processamento, foram incluídos na ferramenta métodos de detecção de manchas escuras, onde é feita a segmentação da imagem usando algoritmos específicos visando separar as manchas escuras que são de fato vazamentos de óleo, daquelas que são formadas por fenômenos naturais (falso-positivos). A plataforma permite que usuários externos incluam algoritmos na plataforma, que podem ser validados usando o grupo de imagens e respectivas máscaras já existentes. No trabalho, os autores apresentam ainda o resultado dos algoritmos que foram testados na plataforma e obtiveram melhores resultados. Sendo que dentre eles, o SKFCM (Spatially Constrained Kernelized Fuzzy C Means) obteve os melhores resultados com 86% de verdadeiros positivos e 98% de verdadeiros negativos.

No trabalho de Yang et al. (2016) foram feitas simulações numéricas em imagens SAR contendo vazamentos de óleo com o objetivo de estudar o mecanismo de espalhamento do óleo na superfície marítima, foram realizados testes considerando diversas condições de mar, de polarização do radar, de frequência e dos ângulos de incidência. O estudo verificou que as condições ideais consistem em alta frequência de radar e polarização VV das imagens.

Topouzelis et al. (2007) apresentam metodologia utilizando duas redes neurais, uma para a detecção das manchas escuras e outra para a classificação dos vazamentos e dos falso-positivos, usando imagens SAR de alta resolução. O método mostrou ser eficiente, sendo que a primeira etapa obteve acurácia de 94% das manchas escuras identificadas e a segunda contou com a classificação correta de 89% das manchas. Para a segunda parte da detecção foram usados dados para discriminar os vazamentos de óleo dos falso-positivos considerando: relação do perímetro pela área (P/A), complexidade do objeto quanto à geometria, forma, desvio padrão (considerando os valores dos pixels).

Marghany (2001) desenvolveu um modelo para a detecção automática de óleo, que inclui análise da textura (para discriminar óleo da água) e os algoritmos Lee (para determinar a linearidade do movimento do óleo) e Gamma (para determinar o espalhamento do óleo). Para a análise da textura, foi calculada uma medida de textura especificada para cada pixel usando matrizes de co-ocorrência de nível de cinza, sem a realização de nenhuma filtragem anterior.



Segunda o autor, a aplicação do método, especificamente em uma imagem RADARSAT de um acidente conhecido, permitiu distinguir a mancha de óleo da água de maneira adequada.

No trabalho realizado por Singha et al. (2013) foram usadas 38 imagens (ENVISAT ASAR e RADARSAT) visando treinar um sistema de detecção automático de óleo, contendo vazamentos de origem identificada e diversos falso-positivos. Na etapa de pré-processamento foi feita filtragem, retirada de ruídos e aplicação de máscara nas áreas de terra. A imagem pré-processada foi então segmentada para identificar as feições que poderiam ser vazamentos ou falso-positivos. Em seguida foi feita a seleção dos atributos com as características consideradas relevantes para a distinção das manchas, considerando elementos de retroespalhamento, forma, tamanho e textura. Na etapa seguinte foram usados dois classificadores, o primeiro constituído por árvore de decisão e o segundo por algoritmo de lógica difusa. Por fim, a metodologia criada foi testada em um conjunto de 118 imagens e a acurácia foi calculada, obtendo para as imagens ENVISAT 85,43% de acurácia e 93,08% para as imagens RADARSAT.

Shi et al. (2008), seguindo a mesma sequência lógica, estabeleceram metodologia, usando mais de 600 imagens ERS-2 e Envisat SAR do norte do mar chinês, onde existiam 120 manchas de óleo conhecidas. Foi feito procedimento similar aos anteriores: pré-processamento da imagem, incluindo reamostragem, filtragem de ruído (filtro Lee) e correção do ângulo de incidência; segmentação de imagens e realce de manchas escuras; por último, a discriminação entre vazamentos de óleo e falso-positivos realizada manualmente por especialista, com base na ocorrência, tamanho, textura (forma, área, tipo de borda e homogeneidade) e contexto da mancha (considerando vento, correntes, localização e distância de pontos brilhantes nas imagens que costumam ser barcos e plataformas). Os resultados do processamento das imagens foram inseridos em um SIG com vetores com informações sobre: localização de plataformas, rotas de navios, linhas de costa e batimetria. Os dados geraram um mapa com a identificação de áreas de risco para poluição por óleo da área de estudo.

O trabalho de Guo e Zhang (2014) parte do princípio de que cada mancha escura identificada numa imagem de satélite, que tenha origens distintas, é constituída de diferentes materiais, tendo, dessa maneira, propriedades físicas diferentes e, com isso, adquirem diferentes formas. Assim os autores desenvolveram metodologia baseada em algoritmo que calcula as interações e relações de atributos relacionados à forma da mancha. Foram usadas duas imagens ERS-2, onde as manchas escuras já estavam previamente identificadas como sendo vazamentos de óleo ou falso-positivos, a partir delas foram feitos os testes, visando verificar quais as relações de atributos representariam maior acurácia e quais não agregariam valor ao cálculo. Por fim, foi realizada classificação por aprendizado de máquina e por rede neural, sendo essa última a que apresentou melhor resultado. Os autores enfatizam a necessidade de durante o processo de detecção de vazamentos de óleo ser dado destaque para a seleção das características a serem usadas para a distinção entre manchas de óleo e falso-positivos, considerando que essa etapa é fundamental para a acurácia final do trabalho.

Lang et al. (2017) desenvolveram metodologia com o diferencial presente na fase de segmentação das manchas escuras, pois para eles essa etapa é crítica e fundamental uma vez que representa impacto significativo nas etapas seguintes. Inicialmente é feita calibração radiométrica, correção geométrica e remoção de *speckle* e ruídos; em seguida foi feita extração de características das manchas (níveis de cinza, geometria e textura); e por fim, foi realizada





segmentação usando redes neurais artificiais e processamento morfológico. O resultado do experimento indica que a proposta de trabalho supera a performance de outras abordagens, tanto na acurácia da segmentação quanto na classificação das manchas encontradas.

Alpers et al. (2017) elencam desafios e equívocos encontrados em estudos realizados para identificação de óleo no mar, destaca-se nesse trabalho a apresentação de experiências para validação em campo de manchas encontradas em imagens de radar que apresentaram baixa performance, como o teste ocorrido no Mar Norte e Mar Báltico onde foram feitos testes com aeronaves equipadas com radar que identificaram 5 manchas de óleo, sendo somente 2 (duas) confirmadas após a coleta de amostra no local. Outro exemplo diz respeito à análise dos dados do banco CleanSeaNet, com imagens de diversas fontes europeias, foi constatada que somente 195 casos de 775 (26%) foram confirmadas.

### III.6 DESAFIOS PARA A AUTOMAÇÃO

Apesar de ter aumentado nas últimas duas décadas o número de pesquisas realizadas para a detecção de óleo no mar, a metodologia científica usada manteve-se constante, não ocorrendo mudanças das regras de detecção, sendo que o principal fator de mudança diz respeito ao fato de ter aumentado significativamente o número de imagens de radar disponíveis, que se tornaram mais acessíveis (TOPOUZELIS e SINGHA, 2016; FINGAS e BROWN, 2018).

Destaca-se a inviabilidade de realizar comparação entre as pesquisas e metodologias existentes, uma vez que elas fazem uso de variado conjunto de dados, relativos aos radares usados, aos recortes geográficos e às condições meteorológicas e oceanográficas de momento (TOPOUZELIS, 2007). Dessa forma, faz-se necessário a realização de testes com as distintas metodologias utilizando o mesmo conjunto de imagens pré-selecionadas que tenham manchas cuja origem seja conhecida, visando tornar possível a comparação quanto à acurácia dos métodos e, a partir dos resultados, propor novas formas de abordagem metodológica.

Segundo Zhang et al. (2014), apesar do aumento da acurácia e eficiência da detecção e classificação automática de vazamentos de óleo ocorrida em anos recentes, a probabilidade de eles operarem de maneira totalmente autônoma é pequena em virtude do número elevado de fenômenos imprevisíveis que podem ser observados em cada imagem SAR analisada, sendo necessário a participação de especialistas no processo.

Topouzelis e Singha (2016) destacam a necessidade de existir um banco de dados robusto contendo informações que tiveram verificação em campo tanto de vazamentos de óleo quanto de falso-positivos, em diversas regiões geográficas e com condições de mar distintas, além de informações sobre diferentes tipos de óleos.

Pesquisas recentes utilizando algoritmos de aprendizado profundo na etapa de classificação de imagens de satélite vêm apresentando resultados promissores que podem implicar no aumento da acurácia dos trabalhos desenvolvidos (CHENG et al., 2018). Esses algoritmos, quando comparados a outros comumente usados para a identificação de manchas de óleo na superfície marítima, demonstraram melhor performance (CHEN et al., 2017), podendo representar possibilidade de avanço na detecção automática de manchas de óleo em imagens de satélite.



### III.7 CONSIDERAÇÕES FINAIS

Este artigo apresentou o levantamento de pesquisas recentes relacionadas ao uso do sensoriamento remoto na detecção de vazamentos de óleo na superfície marinha, com destaque para os trabalhos que usaram imagens SAR, cuja predominância foi verificada, bem como o consenso quanto aos bons resultados no que diz respeito à distinção de manchas de óleo daquelas consideradas falso-positivos. Constatou-se que os mesmos passos metodológicos são usados no processamento das imagens (pré-processamento, segmentação das manchas escuras, estabelecimentos de critérios de decisão e classificação), havendo aperfeiçoamento em cada etapa. Nesse contexto, é necessário o desenvolvimento de novas pesquisas visando a realização de testes e criação de metodologias que permitam otimizar o tempo de análise das imagens, aumentar a eficiência na exclusão de falso-positivos e potencializar o nível de acerto das manchas escuras identificadas como vazamento de óleo. Para tanto, entende-se que o uso de algoritmos de aprendizado profundo representa grande potencial para aumento da acurácia dos resultados. Considerando o cenário brasileiro, onde a área de mar territorial é de grande dimensão e os recursos para vigilância são limitados, sobretudo a capacidade de ida a campo para a coleta de amostra de água, entende-se que o desafio maior seria o desenvolvimento de metodologia que não necessite de exemplos verificados in loco para a sua validação, principalmente quando considerado o número crescente de atividades relacionadas a exploração de petróleo e o número de vazamentos associados. Posteriormente, visando o dimensionamento do dano ambiental causado pelos vazamentos de óleo, devem ser pensadas pesquisas com objetivo de não apenas identificar a mancha, mas também identificar o tipo de óleo e calcular o volume derramado, considerando tamanho e espessura.

### AGRADECIMENTOS

O presente trabalho foi realizado com o apoio da Coordenação de Pessoal de Nível Superior - Brasil (CAPES) – Código de Financiamento 001. Os autores agradecem também ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e à Fundação de Apoio e Pesquisa do Distrito Federal (FAPDF).

### REFERÊNCIAS

ABASCAL, A. J.; SANCHEZ, J.; CHIRI, H.; FERRER, M. I.; CÁRDENAS, M.; GALLEGO, A.; TURRELL, W. R. Operational oil spill trajectory modelling using HF radar currents: A northwest European continental shelf case study. **Marine Pollution Bulletin**, v. 119, n. 1, p. 336-350, 2017.

ALPERS, W.; HOLT, B.; ZENG, K. Oil spill detection by imaging radars: Challenges and pitfalls. **Remote Sensing of Environment**, v. 201, p. 133-147, 2017.

BENTZ, C. M.; POLITANO, A. T.; GENOVEZ, P. Monitoramento ambiental de áreas costeiras e oceânicas com múltiplos sensores orbitais. **Revista Brasileira de Cartografia**, v. 1, n. 57, 2005.



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

BRASIL, **Lei nº 9.966, de 28 de abril de 2000** (Lei do Óleo). Art. 2º das definições e classificações. Disponível em: <[http://www.planalto.gov.br/ccivil\\_03/LEIS/L9966.htm](http://www.planalto.gov.br/ccivil_03/LEIS/L9966.htm)>. Acesso em: 29 outubro 2019.

BREKKE, C.; SOLBERG, A. H. Classifiers and confidence estimation for oil spill detection in ENVISAT ASAR images. **IEEE Geoscience and Remote Sensing Letters**, v. 5, n. 1, p. 65-69, 2008.

BREKKE, C.; SOLBERG, A. H. Feature extraction for oil spill detection based on SAR images. In: **Scandinavian Conference on Image Analysis**. Springer, Berlin, Heidelberg, p. 75-84, 2005.

BREKKE, C.; SOLBERG, A. H. Oil spill detection by satellite remote sensing. **Remote sensing of environment**, v. 95, n. 1, p. 1-13, 2005.

CHEN, G.; LI, Y.; SUN, G.; ZHANG, Y. Application of deep networks to oil spill detection using polarimetric Synthetic Aperture Radar Images. **Applied Sciences**, v. 7, n. 10, p. 968, 2017.

CHENG, G.; YANG, C.; YAO, X.; GUO, L.; HAN, H. When deep learning meets metric learning: Remote sensing image scene classification via learning discriminative CNNs. **IEEE transactions on geoscience and remote sensing**, v. 56, n. 5, p. 2811-2821, 2018.

ESPEDAL, H. A.; JOHANNESSEN, O. M. Cover: Detection of oil spills near offshore installations using synthetic aperture radar (SAR). **International Journal of Remote Sensing**, v. 21, n.11, p. 2141-2144, 2000.

FINGAS, M.; BROWN, C. A review of oil spill remote sensing. **Sensors**, v. 18, n. 1, p. 91, 2018.

FINGAS, M.; BROWN, C. Review of oil spill remote sensing. **Marine pollution bulletin**, v. 83, n. 1, p. 9-23, 2014.

FISCELLA, B.; GIANCASPRO, A.; NIRCHIO F.; PAVESE, P. ; TRIVERO, P. Oil spill detection using marine SAR images. **International Journal of Remote Sensing**, v. 21, n. 18, p. 3561-3566, 2000.

FUSTES, D.; CANTORNA, D.; DAFONTE, C.; ARCA, B.; IGLESIAS, A.; MANTEIGA, M. A cloud-integrated web platform for marine monitoring using GIS and remote sensing. Application to oil spill detection through SAR images. **Future Generation Computer Systems**, v. 34, p. 155-160, 2014.

GARCIA-PINEDA, O.; HOLMES, J.; RISSING, M.; JONES, R.; WOBUS, C.; SVEJKOVSKY J.; HESS, M. Detection of Oil near Shorelines during the Deepwater Horizon Oil Spill Using Synthetic Aperture Radar (SAR). **Remote Sensing**. v. 9, n. 6, p. 567, 2017.

GARCIA-PINEDA, O.; MACDONALD, I.; HU, C.; SVEJKOVSKY, J.; HESS, M.; DUKHOVSKOY, D.; MOREY, S. L. Detection of floating oil anomalies from the Deepwater Horizon oil spill with synthetic aperture radar. **Oceanography**. v. 26, n. 2, p. 124-137, 2013.

GARCIA-PINEDA, O.; ZIMMER, B.; HOWARD, M.; PICHEL, W.; LI, X.; MACDONALD, I. R. Using SAR images to delineate ocean oil slicks with a texture-classifying neural network algorithm (TCNNA). **Canadian Journal of Remote Sensing**, v. 35, n. 5, p. 411-421, 2009.



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

GUO, Y.; ZHANG, H. Z. Oil spill detection using synthetic aperture radar images and feature selection in shape space. **International Journal of Applied Earth Observation and Geoinformation**, v. 30, p. 146-157, 2014.

JONES, B. A comparison of visual observations of surface oil with Synthetic Aperture Radar imagery of the Sea Empress oil spill. **International Journal of Remote Sensing**, v. 22, n. 9, p. 1619-1638, 2001.

KERAMITSOGLU, I.; CARTALIS, C.; KIRANOUDIS, C. T. Automatic identification of oil spills on satellite images. **Environmental modelling & software**, v. 21, n. 5, p. 640-652, 2006.

LANG, H.; ZHANG, X.; XI, Y.; ZHANG, X.; LI, W. Dark-spot segmentation for oil spill detection based on multifeature fusion classification in single-pol synthetic aperture radar imagery. **Journal of Applied Remote Sensing**, v. 11, n. 1, p. 015006, 2017.

MARGHANY, M. RADARSAT automatic algorithms for detecting coastal oil spill pollution. **International Journal of Applied Earth Observation and Geoinformation**, v. 3, n. 2, p. 191-196, 2001.

MISRA, A.; BALAJI, R. Simple approaches to oil spill detection using sentinel application platform (SNAP) - ocean application tools and texture analysis: a comparative study. **Journal of the Indian Society of Remote Sensing**, v. 45, n. 6, p. 1065-1075, 2017.

PISANO, A.; DE DOMINICIS, M.; BIAMINO, W.; BIGNAMI, F.; GHERARDI, S.; COLAO, F.; COPPINI, G.; MARULLO, S.; SPROVIERI, M.; TRIVERO, P.; ZAMBIANCHI, E. An oceanographic survey for oil spill monitoring and model forecasting validation using remote sensing and in situ data in the Mediterranean Sea. **Deep Sea Research Part II: Topical Studies in Oceanography**, v. 133, p. 132-145, 2016.

SHI, L.; IVANOV, A. Y.; HE, M.; ZHAO, C. Oil spill mapping in the western part of the East China Sea using synthetic aperture radar imagery. **International Journal of Remote Sensing**, v. 29, n. 21, p. 6315-6329, 2008.

SINGHA, S.; VESPE, M.; TRIESCHMANN, O. Automatic Synthetic Aperture Radar based oil spill detection and performance estimation via a semi-automatic operational service benchmark. **Marine pollution bulletin**, v. 73, n. 1, p. 199-209, 2013.

TOPOUZELIS, K. Oil spill detection by SAR images: dark formation detection, feature extraction and classification algorithms. **Sensors**, v. 8, n. 10, p. 6642-6659, 2008.

TOPOUZELIS, K.; KARATHANASSI, V.; PAVLAKIS, P.; ROKOS, D. Detection and discrimination between oil spills and look-alike phenomena through neural networks. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 62, n. 4, p. 264-270, 2007.

TOPOUZELIS, K.; SINGHA, S. Oil spill detection: Past and future trends. In: **Proceedings of the ESA Living Planet Symposium**. 2016.

YANG, W.; QI, C.H.; ZHAO, Z. Q. Numerical Simulation of Synthetic Aperture Radar Images for Ocean Oil Spill Pollution. **Electromagnetics**, v. 36, n. 1, p. 32-43, 2016.

YU, F.; SUN, W.; LI, J.; ZHAO, Y.; ZHANG, Y.; CHEN, G. An improved Otsu method for oil spill detection from SAR images. **Oceanologia**, v. 59, n. 3, p. 311-317, 2017.



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

ZHANG, Y.; LI, Y.; LIN, H. Oil-spill pollution remote sensing by synthetic aperture radar. In: **Advanced Geoscience Remote Sensing**. p. 27-50, 2014.



## CAPÍTULO IV

### **DEEP-WATER OIL-SPILL MONITORING AND RECURRENCE ANALYSIS IN THE BRAZILIAN TERRITORY USING SENTINEL-1 TIME SERIES AND DEEP LEARNING**

#### **ABSTRACT**

Oil spills are a worldwide concern since they cause environmental problems and financial losses. Automatic detection plays a crucial role in rapid decision-making to reduce damage. In this context, deep learning and remote sensing are powerful tools with successful applications in many regions. However, there are still no studies on deep-water zones and in the Brazilian territory. The present research has three contributions: (1) create an oil spill dataset on the Brazilian region, (2) compare state-of-the-art deep learning models for this task, and (3) propose a novel application on the Campos Basin (Brazil's largest producer) using Sentinel-1 time series to identify more susceptible regions, encompassing 138 images from 2016 to 2021. The experts manually labeled the dataset with confirmation from the oil company and federal inspection, resulting in 800 images with 512x512 spatial dimensions and their respective annotations (600 for training, 125 for validation, and 75 for testing). The study compared three semantic segmentation architectures (U-net, DeepLabv3+, and LinkNet) with four backbones (ResNet-101, ResNet-50, Efficient-net-B0, and Efficient-net-B3) resulting in 12 models. The U-net with the Efficient-net-B3 backbone presented slightly better results (98% accuracy, 75% precision, 78% recall, 76% F-score, and 62% IoU). The time-series analysis considered images with 8,192 x 11,264 spatial dimensions. The entire image classification used a sliding window approach with a 128-pixel stride (averaging the overlapping pixels). Moreover, recurrence analysis detected the more susceptible areas and eliminated the look-alike. False-positive features have a high spatial presence, but with low recurrence (rarely reaching 3 events), which facilitates their elimination using a threshold recurrence. This novel analysis for oil spills is suitable for understanding the patterns along the time and providing regions for the authorities in real-time.

**Keywords:** Coastal Management; Semantic Segmentation; Campos Basin



## VI.1. INTRODUCTION

Oil production is one of the most important economic activities worldwide because of its vast applications in various segments (e.g., cosmetics, medical drugs, synthetic fabric). The increasing oil demand and its exploration make oil spills more frequent with ship accidents, broken pipelines, explosions, among others. Apart from the economic loss, the oil spills lead to severe pollution affecting the marine ecosystems and coastal areas. Cleaning up oil spills is a complex logistical procedure in which early detection is essential for minimizing environmental damage and contacting those responsible.

Therefore, remote sensing technologies are essential for allowing continuous monitoring, and coverage of large areas at relatively low costs. Different review articles address the use of remote sensing in oil spill detection, considering different sensors, algorithms, and monitoring systems (de Moura et al., 2020; Fingas and Brown, 2014, 2018; Leifer et al., 2012; Solberg, 2012; Vasconcelos et al., 2020). Some revisions are specific to radar image-processing for oil spill detection, which are prevalent due to all-weather and all-day capabilities, ensuring constant data acquisition (Brekke and Solberg, 2005; Gens, 2008; Zhang et al., 2014). The sea surface in Synthetic Aperture Radar (SAR) images presents a rough texture and bright spots due to capillary waves formed by wind, intensifying microwave scattering (Zhang et al., 2014). Oil in water forms a film that attenuates the effect of capillary waves and generates dark spots on the SAR images that differ from their surroundings due to the low wave backscatter coefficient (Alpers et al., 2017; Fingas and Brown, 2014; Fiscella et al., 2000; Pisano et al., 2016). However, other phenomena also attenuate the surface, such as biogenic oil films and the absence of wind, generating dark spots that cause identification errors (Brekke and Solberg, 2005; de Moura et al., 2020; Marghany, 2001).

Deep Learning (DL) is currently the state-of-the-art for computer vision and remote sensing image processing (Ma et al., 2019; Yuan et al., 2020), demonstrating relevant results for ocean studies (Li et al., 2020). Recent review articles on oil spill detection by remote sensing subdivide the algorithms into classical methods (traditional procedures and machine learning) and DL-based methods (Al-Ruzouq et al., 2020; Yekeen and Balogun, 2020). Different DL strategies have been used in the oil-spill studies: (a) image classification - the image receives a label describing the presence or absence of the object; (b) pixel-based classification -



categorizes and labels pixels in an image by attributes present in the pixel level; (c) object detection - establishes target location with a bounding box; (d) semantic segmentation - establishes the exact boundary of targets by associating each pixel of a target with its class label; and (e) instance segmentation - differs multiple objects of the same class as distinct individual instances.

In DL, image classification consists of assigning a label to it. These studies subdivide the image into frames, indicating or not the presence of oil. [De Laurentiis et al. \(2020\)](#) used this technique to label “oil” or “non-oil” in Gulf of Mexico frames with dimensions 128x128 and 256x256 using Sentinel-1 images and two different Convolutional Neural Networks (CNN) architectures (InceptionResNet and Xception). [Zeng and Wang \(2020\)](#) used AlexNet, VGG16, and VGG19 algorithms in three types of images (Envisat/C, ERS-1.2/C, COSMO Sky-Med/X), using 64x64 frames from different regions (Bohai Bay of China, China Sea, Gulf of Mexico, European Seas). Finally, [Wang et al. \(2021\)](#) used AlexNet to assign 16x16 frames from Radarsat-2 and GF-3 images. Few studies have applied DL's pixel-based oil spill classification, concentrating on multidimensional images, such as hyperspectral data ([Zhu et al., 2019](#)) and RADARSAT-2 quadripolarimetric SAR imaging ([Chen et al., 2017](#)).

Table 1 lists oil detection studies using the most used DL methods in remote sensing. Semantic segmentation concentrates most of the studies due to its ability to delimit oil spills at a pixel level. Instance segmentation presents only one study, in part because the individual detection of each oil segment is not as relevant as in other targets where the counting of individual elements is highly relevant such as vehicles ([Mou and Zhu, 2018](#)), center pivots ([Albuquerque et al., 2021](#); [Carvalho et al., 2020](#)), and others. A single oil spill can have amorphous and discontinuous shapes, which form different instances.

The Brazilian Institute of Environment and Renewable Natural Resources (IBAMA) licenses offshore platforms for oil exploration and monitors oil spills in Brazil. The actual methodology uses visual interpretation from specialists. Apart from being laborious work, it depends on the specialist experience for correctly identifying the targets. The challenge in oil spill remote sensing is the ability to distinguish false positives, especially those formed by low wind areas ([Bianchi et al., 2020](#); [Brekke and Solberg, 2005](#); [Fiscella et al., 2000](#)). Furthermore,





the intensification of exploration and traffic in Brazilian coastal areas requires a surveillance system based on artificial intelligence, achieving more speed and efficiency.

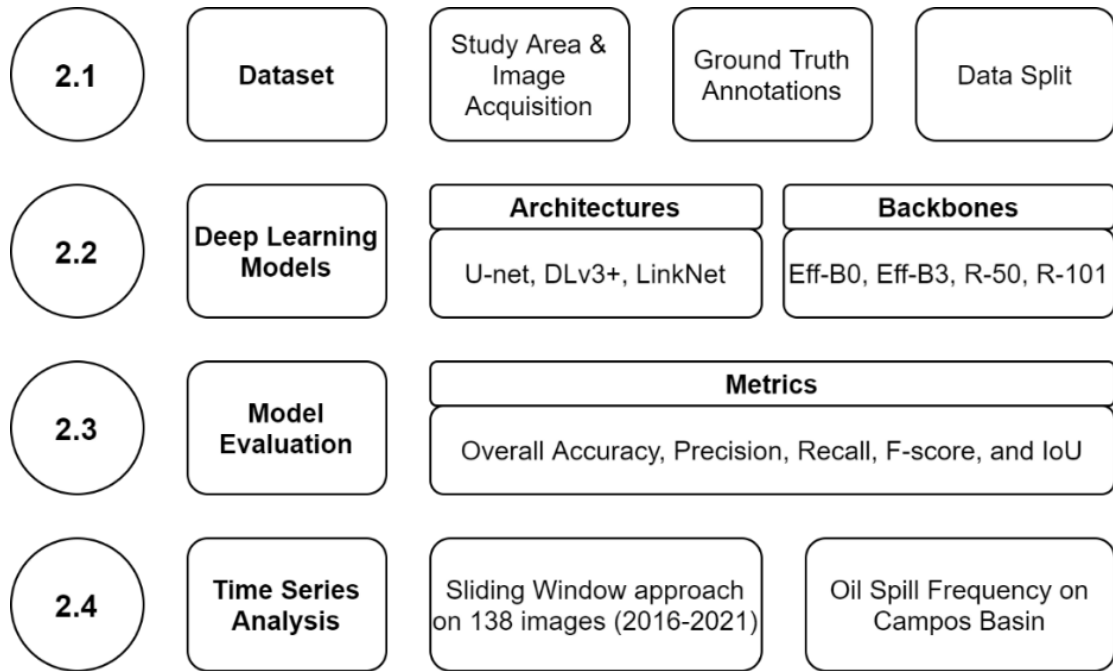
This research aims to detect oil spill events in Campos Basin (deep-water depositional systems), create an oil spill dataset on the Brazilian region, and establish zones of greater occurrence. The study compares 12 DL models from a combination of three architectures (U-net, DeepLabv3+, and LinkNet) and four backbones (ResNet-101, ResNeXt-101, Efficient-net-B3, and Efficient-net-B7). This proposal allows increasing the speed and efficiency of identification, reducing the current manual work.

**Table 1.** Deep Learning methods, images, and study areas for oil spill detection. Residual Encoder-Decoder Networks is RED-Net, and S1 is Sentinel-1.

Article	Study Area	Image	Architecture	Backbone	Frame size (pixels)
<b>Object Detection</b>					
Jiao et al. (2019)	China	UAV	Fast-RCNN, Faster-RCNN, YOLO, SSD	AlexNet, GoogLeNet, Inception V1, ResNet-101, and VGG16	4000x2250
<b>Semantic Segmentation</b>					
Krestenitis et al. (2019)	European Maritime Safety Agency (EMSA)	S1	U-net, LinkNet, PSPNet, DeepLabv2, DeepLabv2 (msc), DeepLabv3+ (best model),	ResNet-101 and MobileNetv2 (for DeepLabv3+)	320x320 (U-net, LinkNet), 336x336 (PSPNet), 321x321 (DeepLabv2, DeepLabv2 (msc), DeepLabv3+)
Bianchi et al. (2020)	Northern Europe	S1	U-net, DeeplabV3+, OFCN	Xception and Mobilenet (DeeplabV3+)	160 x 160
Cantorna et al. (2019)	Spanish Maritime Safety Agency	Envisat and S1	ConvNet	-	128x128
Gallego et al. (2018)	Spain	SLAR	SelAE and Residual Encoder-Decoder Networks (RED-Net)	-	256x256 and 384x384
Guo et al. (2017)	Mexico Bay, North Sea of Europe, South China Sea	Radarsat-2	Segnet	-	four window sizes (500x500, 1000x1000, 1500x1500, and 2000x2000) that were resized into 256x256
Nieto-Hidalgo et al. (2018)	Spain	SLAR	Two stage CNN	-	28x28 or 50x50
<b>Instance Segmentation</b>					
Yekeen et al. (2020)	Malaysia	S1	Mask-RCNN	ResNet-101	1024x1024

## VI.2 MATERIAL AND METHODS

This study had the following methodological steps: (2.1) Dataset; (2.2) DL models; (2.3) Model Evaluation; and (2.4) Time Series Evaluation (**Figure 1**).



**Figure 1.** Methodological flowchart.

### VI.2.1. Dataset

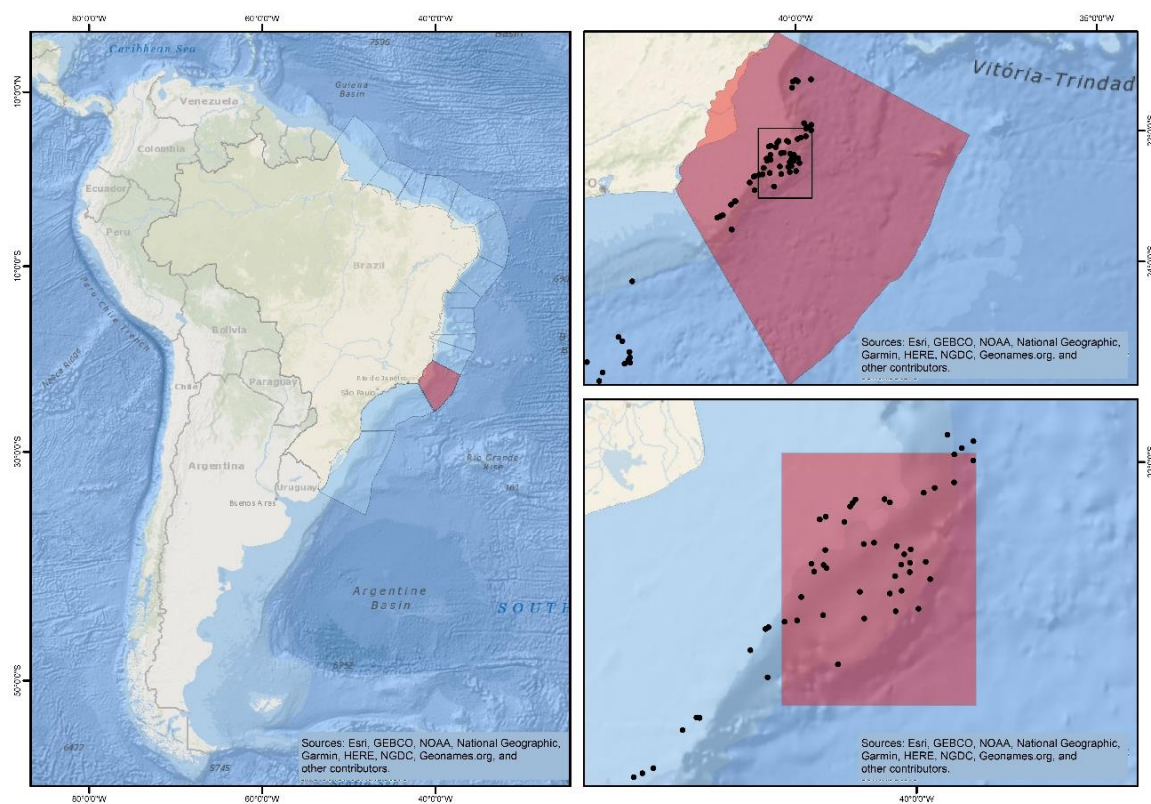
#### VI.2.1.1 Study Area

The study area is the oceanic region of the Campos Basin (southeastern Brazil) that extracts oil and gas from the deep-water sedimentary systems in post-salt drift formations. The area covers 500 km in the north/south and 150 km in the east/west direction, achieving an area greater than 100,000 km<sup>2</sup>, where the city of Cabo Frio is the southern boundary, and Vitória is the northern limit (Kang et al., 2018). This region is the second-largest Brazilian oil producer, corresponding to 27% of national production (ANP, 2021).

#### VI.2.1.2 Image Acquisition

The European Space Agency (ESA) SAR Sentinel-1 mission has a constellation of two polar-orbiting satellites (Sentinel-1A and Sentinel-1B) operating on the C-band (5.4 GHz) in VV (vertical transmission, vertical reception) and VH (vertical transmission, horizontal

reception) polarizations, available free of charge (<https://scihub.copernicus.eu/dhus/#/home>). However, only Sentinel-1B operates on the Brazilian coast, generating images every 12 days. The acquired images were Interferometric Wide Swath (IW), Level-1 Ground Range Detected (GRD), and VV polarization. The VV polarization has less noise influence and better identifies the characteristics of the oil in the sea, providing more contrast with the adjacent areas (Chaturvedi et al., 2020).



**Figure 2.** Study Area with the platform points.

The analysis considered a time series with 138 images between 2016 and 2021. The SAR images pre-processing considered the following procedures using the Sentinel Application Platform (SNAP) software (Filipponi, 2019): apply orbit file, thermal noise removal, border noise removal, calibration (conversion from digital pixel values to radiometrically calibrated SAR backscatter), speckle filtering (Lee Sigma filter), range-Doppler terrain correction using the Global Earth Topography and Sea Surface Elevation at 30 arc-second resolution data (GETASSE30), and backscattering conversion to decibels (dB).



### VI.2.1.3 *Ground truth Annotations*

A significant challenge for oil-spill detection in SAR images is creating a good dataset, often requiring confirmed spill events, which presents high costs and logistical difficulties for data collection. The ground truth annotation used visual interpretation from the oil spills confirmed by IBAMA, including accidents reported by the polluting company because of compliance with art. 22, of Law No. 9,966, of April 28, 2000 (Petroleum Law) (BRAZIL, 2000), and leaks detected by IBAMA aircraft equipped with SLAR, Visible Line Scanner, IR/UV Line Scanner, Microwave Radiometer (MWR) e Laser Fluorosensor Light (LFSL). Even with confirmed events, oil spill annotations present additional difficulties, especially when dealing at a pixel level:

1. The shapes are amorphous;
2. The oil slicks vary a lot from each other;
3. High-class imbalance from background pixels and oil-spill pixels;
4. There are varying levels of the water-oil mixture (an additional difficulty for encountering the exact shape);
5. There are many look-alikes;
6. There is only a single frame in time for generating the annotations since the oil spills are very dynamic;
7. SAR images are very noisy.

### VI.2.1.4 *Data Split*

Data division into training, validation, and test considered the years of the time series, in which the images from 2017 and 2018 were for training, 2019 for validation, and 2020 for testing (Table 2). For each image in the training and validation, we considered tiles of 512x512 spatial dimensions. Most features constituted of elongated, straight, or slightly curved, predominantly appearing next to oil exploration platforms (bright spot due to the intense backscatter of the structure).

**Table 2.** Data split in training (Train), validation (Val), and testing (Test) sets, with the respective number of 512x512 images, and their respective percentage.

Set	Number of images	Percentage (%)
Train	600	75



<b>Val</b>	125	15.625
<b>Test</b>	75	9.375

## VI.2.2 Deep Learning Models

Semantic segmentation models outputs a pixel-wise mask with the same dimensions as the input image (Guo et al., 2018; Ma et al., 2019). Most architectures present contraction and expansion paths, also known as encoder and decoder. The encoder is responsible for extracting relevant features while downsampling the spatial image dimensions. The decoder restores the image dimensions for accurate and matching pixel-wise classifications compared to the input image. Even though the idea is similar among different models, various peculiarities may yield better results depending on the application.

This research considered three architectures: (1) U-net (Ronneberger et al., 2015), (2) DeepLabv3+ (Chen et al., 2018), and (3) LinkNet (Chaurasia and Culurciello, 2017). The U-net and LinkNet are very similar. However, the LinkNet combines the encoder and decoder by addition, whereas the U-net uses concatenations. The DeepLabv3+ considers classifying objects of varying-sized objects by using dilated convolutions with different atrous rates.

Moreover, the feature extraction section (i.e., encoder) may use different CNNs to boost the performance. Recently, the development of better CNNs has been very prominent in the computer vision community. Besides the three architectures, we compared them using four different encoders (resulting in 12 distinct combinations): (1) ResNet-101 (R-101) (He et al., 2016), (2) ResNet-50 (R-50), (3) Efficient-net-B3 (Eff-B3) (Tan and Le, 2019), and (4) Efficient-net-B0 (Eff-B0). The ResNets are one of the most famous CNNs, introducing the concept of residual learning, which prevents some problems such as vanishing gradients. Most recently, the Efficient-nets presented state-of-the-art results by scaling the depth, width, and resolution of the CNNs. The scaling can consider different ratios, and the original paper considers eight stages (from B0 to B7), in which the B7 is the most complex model.

Most models acquire a high performance with slight differences, adjusting the model settings to the specific problem. The first adaptation is the input image. Usually, most computer vision problems use RGB images with three channels. SAR images contain a single channel in our research, resulting in an input shape of 512 (height) x 512 (width) x 1 (channels). The binary cross-entropy (BCE) was the loss function, and the models used the following hyperparameters:



(a) Adam optimizer, (b) learning rate of 0.001, (c) batch size of 5. Besides, we saved the models with the lowest BCE loss on the validation set.

The models used the Segmentation Models Pytorch repository (Yakubovskiy, 2020), which is very high-level and straightforward, being easy to test and compare different configurations. The computer contained an NVIDIA RTX 2080TI with 11GB RAM and i7 processor.

### VI.2.3 Model Evaluation

The model evaluation considered per-pixel metrics, aiming to compare the differences in the predicted segmentation mask and the ground truth mask. A very intuitive way to compare the predictions with the ground truth is using the confusion matrix, which for each pixel may yield four results: (1) True Positives (TP), (2) True Negatives (TN), (3) False Positives (FP), and (4) False Negatives (FN). Thus, we evaluated five commonly used metrics from these attributes: (a) overall accuracy, (b) precision, (c) recall, (d) f-score, and (e) Intersection over Union (IoU) (Table 3). The DL predictions range from zero to one, while the ground truth data consider binary data (zero or one). Thus, we considered a 0.5 cutoff point to generate a confusion matrix and subsequent metrics.

**Table 3.** List of used metrics with their corresponding equations.

Metric	Equation
Overall accuracy	$\frac{TP + TN}{TP + TN + FP + FN}$
Precision	$\frac{TP}{TP + FP}$
Recall	$\frac{TP}{TP + FN}$
F-score	$\frac{2 \times (Precision \times Recall)}{Precision + Recall}$
IoU	$\frac{TP}{TP + FP + FN}$



#### **VI.2.4 Large-area classification using sliding window approach**

One of the main challenges is identifying the oil spills in large images since the DL samples (512x512 pixels) are very small compared to the vast coastal areas. Thus, incorporating mechanisms to classify large areas is crucial for this task. Previous studies on other targets reported a sliding window approach with varying stride values (Costa et al., 2021; da Costa et al., 2021; de Albuquerque et al., 2020). Reducing stride values improves performance by attenuating border errors from consecutive frames, giving better pixel and visible results. However, a drawback when using narrow stride values is a significant increase in computational cost. Considering the long time series analyzed, we used the constant stride value of 128 pixels (i.e., one-fourth of the image dimensions) in the X and Y directions.

#### **VI.2.5 Oil-Spill Recurrence in the Campos Basin**

Defining susceptible oil spills zones is vital to guide enforcement activities using aircraft and ships. The oil-spill recurrence can detect priority areas for surveillance by considering the number of events per pixel in a time interval (Bayramov et al., 2018). The present study evaluated a time series with 138 images for the study area with 8096 x 11216 pixels spatial dimensions.

An inherent factor in oil-spill detection using SAR imagery is the presence of look-alikes, which are often difficult to identify, even considering experienced professionals. Studies using DL also report a high presence of look-alikes. For example, Bianchi et al. (2020) evaluated three testing areas, presenting 2 TP and 7 FP for area 1, 11 TP and 59 FP for area 2, and 31 TP and 14 FP for area 3. There is a high proportion of FP, and one challenge is to minimize their influence and highlight factors that can predict future events. Subsequent analysis of time series data is a suitable strategy to understand fundamental processes and eliminate noise. The recurrence threshold is crucial, considering as small a value as possible but ensuring relevant information filtering. The evaluation of the threshold value considered three recurrence results: the total result of events from DL, proven events and interpreted by experts, only look-alike events.



## VI.3. RESULTS

### VI.3.1. Metric Evaluation

The three model architectures achieved similar results. However, the U-net with the Eff-B3 backbone presented the highest IoU and F-score values (Table 4). The Eff-B3 presented the best results within each tested architecture. Besides, oil spills usually present a high class-imbalance ratio (more pixels belong to the background class). Thus, the overall accuracy metric is very little informative, achieving more than 98.7% in all models, even with more significant differences in the other metrics. The models presented different tradeoffs between precision and recall, since the Dice Loss was the loss function (which increases the f-score). All models using the DLv3+ architecture presented a precision score higher than the recall. In contrast, only the model with the R-50 backbone showed a precision value greater than the recall using the U-net architectures. The LinkNet presented two models with higher precision (R-101 and R-50).

**Table 4.** Accuracy metrics (accuracy, Intersection over Union (IoU), Precision, Recall, and F-score) results on the test set for DeepLabv3+ (DLv3+), U-net, and LinkNet, using the Efficient-net-B3 (Eff-B3), ResNet-101 (R-101), and ResNeXt-101 (X-101) backbones.

Model	Backbone	Accuracy	Precision	Recall	F-Score	IoU
DLv3+	Eff-B3	98.94	77.49	74.46	75.94	61.22
	Eff-B0	98.88	76.59	71.87	74.16	58.93
	R-101	98.90	76.97	72.36	74.59	59.48
	R-50	98.86	78.88	65.91	71.81	56.02
U-net	Eff-B3	98.94	75.17	78.27	76.69	62.19
	Eff-B0	98.69	70.11	72.50	71.29	55.38
	R-101	98.71	69.79	73.48	71.59	55.75
	R-50	98.84	77.96	65.99	71.47	55.61
LinkNet	Eff-B3	98.87	73.78	76.85	75.29	60.37
	Eff-B0	98.77	71.92	73.57	72.73	57.15
	R-101	98.75	74.56	67.15	70.66	54.63
	R-50	98.79	78.79	62.58	69.75	53.55


The difficulty of delineating a ground truth mask can lead to errors in the oil-spill edges, mainly in fine and elongated features, that significantly reduce accuracy metric values yet appear visually accurate. Figure 3 shows four examples of detected oil spills with relatively low





Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

IoU scores at 34.59 (Figure 3A), 36.72 (Figure 3B), 47.48 (Figure 3C), and 44.80 (Figure 3D). Although the IoU is low, the recall has better values (80.81, 86.79, 88.00, and 58.96, respectively), demonstrating the model prediction hit percentage within the samples mapped as oil-spill ground truth. In contrast, large oil spills proportionally decrease edge errors due to the presence of more target pixels. Figure 4 shows four examples of wider oil spills that present a higher IoU score of 90.75 (Figure 4A), 66.55 (Figure 4B), 88.66 (Figure 4C), and 74.80 (Figure 4D), respectively.



**Figure 3.** Four examples of samples with low IoU values due to oil spills being narrow and elongated, although the prediction was correct.




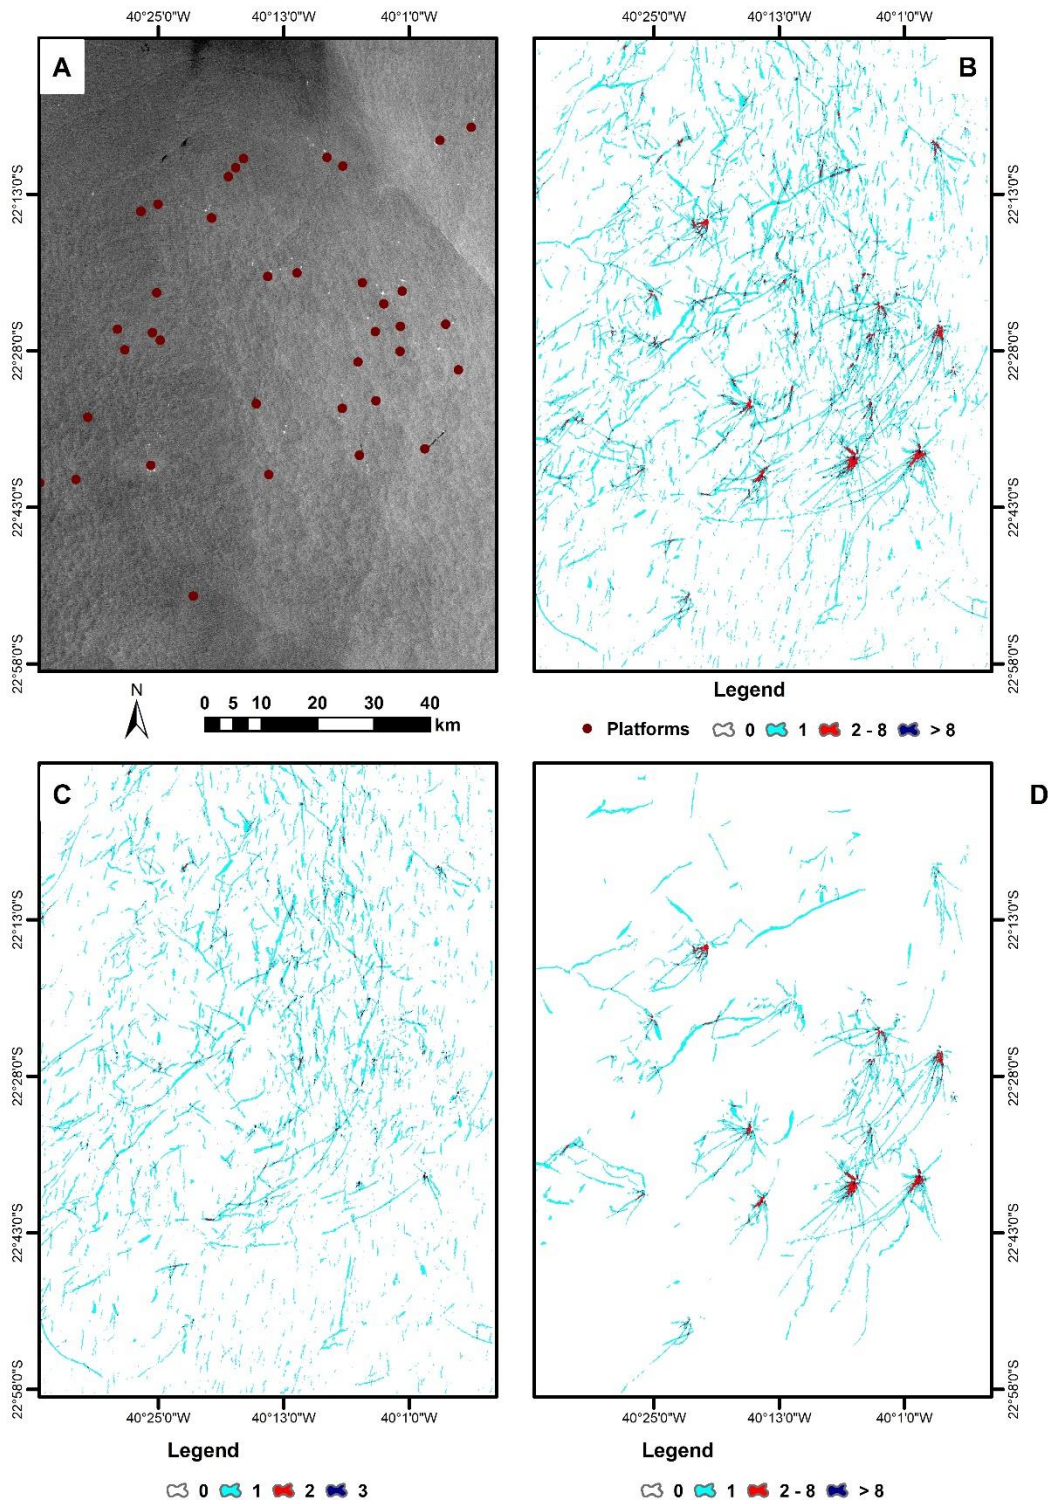
Figure 4. Four examples of samples with larger oil spills that resulted in higher IoU values.



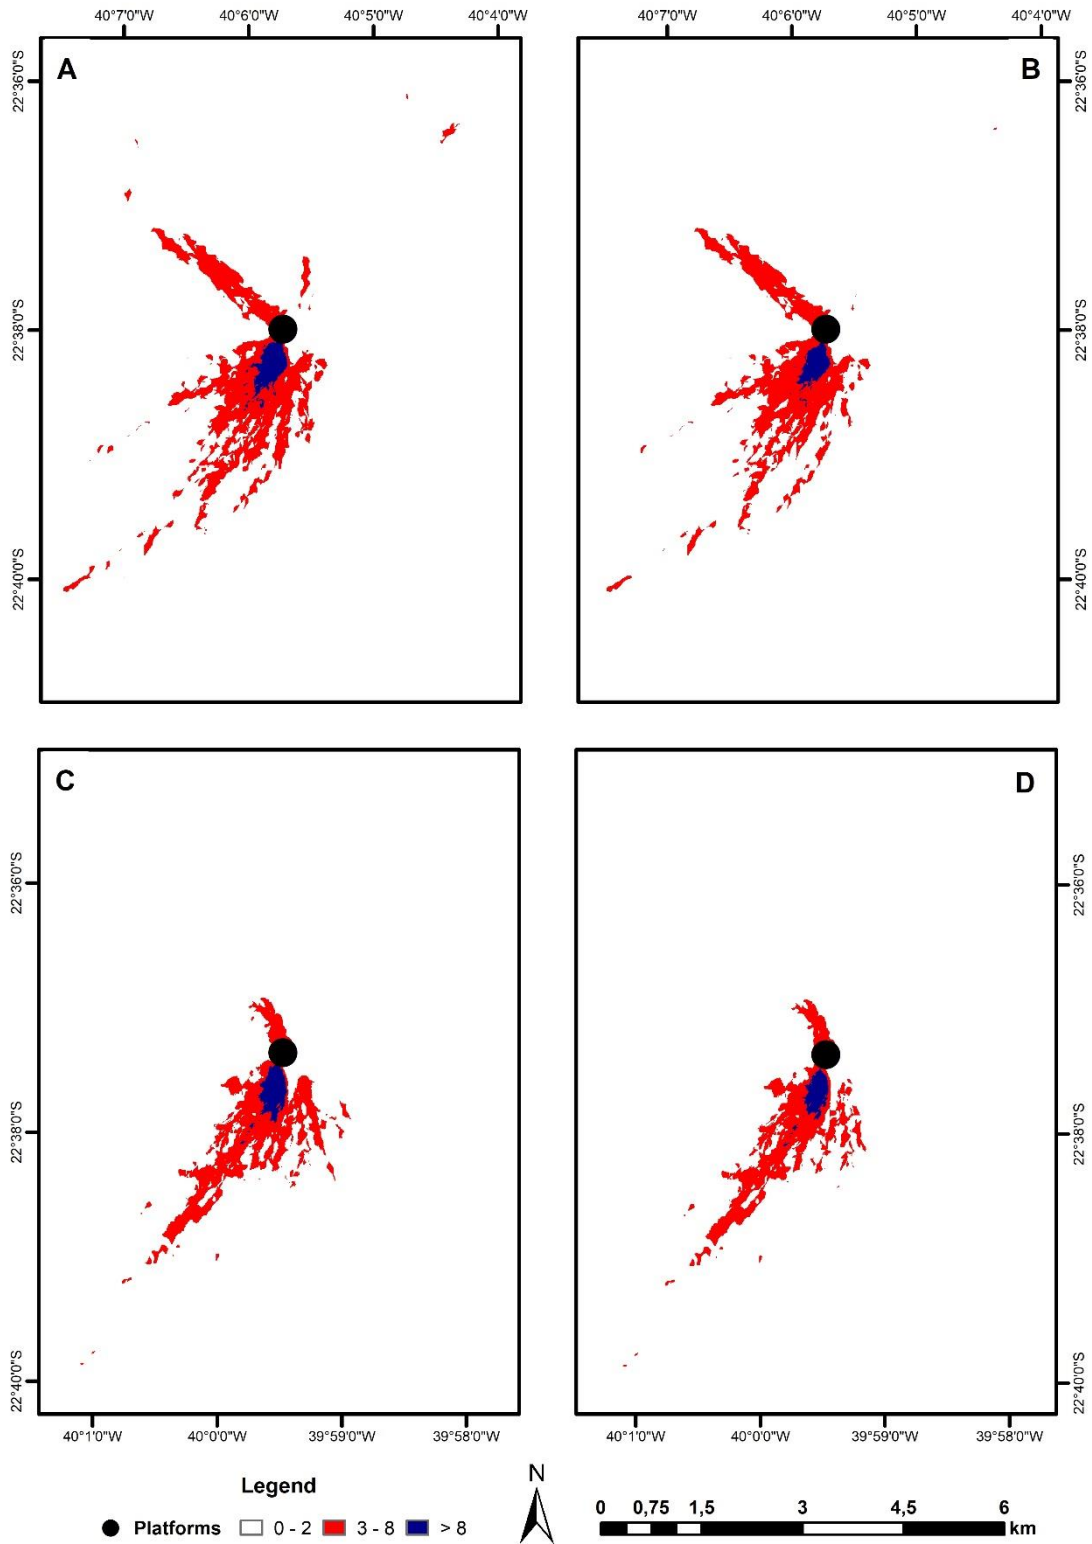
Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

### **VI.3.2. Time Series Analysis**

The recurrence results highlight the zones with the largest oil spills over 2016-2021 (Figure 5). Figure 5B shows the recurrence events considering all DL predictions, while Figure 5C and 5D shows the look-alikes and confirmed oil events, respectively. Look-alike events have significantly lower recurrence values than oil spills, where most have one event and rarely show pixels with 2 or 3 events. A threshold above 2 for practically eliminates all look-alikes and emphasizes confirmed high-recurrence points, which are strongly related to the platform positions (Figure 5A). Figure 6 shows that using a threshold greater than 2, makes the DL prediction very similar to the confirmed oil spill events.



**Figure 5.** (A) Time series and location of oil platforms, (B) oil-spill recurrence map using Deep Learning, (C) look-alike recurrence map, and (D) confirmed oil-spill map.



**Figure 6.** Detailed scale comparison on two platforms between oil spill recurrence results with a threshold  $>2$  for the deep learning (A and C) and the confirmed feature results (B and D).

## VI.4. DISCUSSION

### VI.4.1. Deep Learning models for oil-spill classification

Oil-spill accuracy metrics achieve fewer values than other objects studied in remote sensing. These results are inherent in oil spills due to the amorphous shape with different oil sizes and configurations. In the specific case of the Campos Basin, an aggravating factor for the loss of accuracy metrics is the predominance of oil spills with thin and long formats, which increases the edge error and look-alike.

The DL architectures presented similar metrics compatible with other studies on oil spills using semantic segmentation and Sentinel-1 images. [Bianchi et al. \(2020\)](#) proposed the Oil Fully ConvNet (OFCN) method and obtained the following IoU values for three different test areas: 0.81, 0.52, and 0.36, demonstrating a high variation between areas. [Krestenitis et al. \(2019\)](#) compared six DL models for oil spills and obtained the following IoU values: 53.79 (U-net), 53.38 (DeepLabv3+), 51.53 (LinkNet), 49.53 (DeepLabv2 -msc), 40.10 (PSPNet), and 25.57 (DeepLabv2). Our results presented a ranking of the best methods like [Krestenitis et al. \(2019\)](#) with IoU values of 62.19 (U-net), 61.22 (DeepLabv3 +), and 60.37 (LinkNet).

Usually, boundary-localized errors in semantic segmentation occur due to the inaccuracy of the pixel position that limits the object, consisting of a challenging problem ([Heller et al., 2018](#)). Furthermore, elongated features have a small number of pixels in their width, presenting difficulties similar to those of small objects ([Tong et al., 2020](#)), lacking information to distinguish them from the background. Finally, another factor in the increase in errors is the difficulty obtaining the exact oil spill limit through visual interpretation due to their non-uniform dispersion in the water. Therefore, inaccurate manual ground truth labeling is already difficult for well-defined objects and worse for amorphous targets.

### VI.4.2. Large Image Classification

The entire image segmentation used the sliding window method with 512x512-pixel size and 128-pixel stride to ensure an overlapping area that corresponds to half of the window



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

in the X and Y direction. The window size was the  $2^n$  value largest according to the computational capacity of the equipment used. Studies show that patch edges concentrate errors and that the larger window size minimizes this interference (de Bem et al., 2020). Other studies with semantic segmentation for oil spills used smaller patch size values, such as 28x28 pixels and 50x50 pixels (Nieto-Hidalgo et al., 2018), 128x128 pixels (Cantorna et al., 2019), 160x160 pixels (Bianchi et al., 2020), 256x256 pixels and 384 x 384 pixels (Gallego et al., 2018), and 320x320 pixels, 321x321 pixels and 336x336 pixels (Krestenitis et al., 2019). Guo et al. (2017) used four window sizes (500x500, 1000x1000, 1500x1500, and 2000x2000) that were resized into 256x256 pixels.

#### **VI.4.3. Time series recurrence analysis**

The recurrence analysis allows highlighting priority areas for surveillance and eliminating look-alikes. Look-alikes are an inherent feature in detecting oil spills from SAR images, being a significant obstacle even for skilled professionals. DL models using many images still present a lot of FP errors. Bianchi et al. (2020) trained a DL model using 149,856 images and showed a high incidence of look-alikes in the testing areas. Due to this challenging condition, we proposed a mechanism for evaluating time-series using a recurrence analysis for oil spill monitoring. The FPs are characterized by their constant presence but with low recurrence. In this study, a threshold value above two eliminates most look-alike features. Therefore, the method is efficient to filter look-alikes and highlights priority areas for surveillance. This analysis highlights the platforms with the most significant amount of leakage over time.

## **5. CONCLUSION**

DL frameworks have dominated research on ocean remote-sensing imagery, getting more complex functions with improved accuracy and productivity. This study uses deep learning methods to map oil spills in the Brazilian coastal deep-water regions. Deep-learning oil spill studies are taking place near the coastal zone in regions of Europe, China, and the Gulf of Mexico, and they are still poorly addressed both in deep-water and Brazil. The present research evaluated 12 different combinations considering three architectures (U-net,





Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

DeepLabv3 + and LinkNet) and four different backbones (ResNet-101, ResNeXt-101, Efficient-net-B3 and Efficient-net-B7). The best model was U-net with the Efficient-net-B3 backbone presented slightly better results, achieving the following 98% accuracy, 75% precision, 78% recall, 76% F-score, and 62% IoU. Errors occur mainly at the oil-spill boundaries, intensifying in long, narrow features. Therefore, image annotation is essential for supervised DL tasks, requiring detail and extensive training dataset in areas proven by the exploration company or federal inspector. Recurrence analysis allowed us to delimit areas of greater occurrence and priority for surveillance (correlated to the presence of platforms) and eliminate false positives. The proposed method seeks to optimize monitoring the 3.5 million square kilometers of the Brazilian maritime space, allowing a more efficient warning system.

## References

- Agência Nacional do Petróleo, 2021. Boletim da Produção de Petróleo e Gás Natural. ANP, Brasília.
- Al-Ruzouq, R., Gibril, M.B.A., Shanableh, A., Kais, A., Hamed, O., Al-Mansoori, S., Khalil, M.A., 2020. Sensors, features, and machine learning for oil spill detection and monitoring: A review. *Remote Sens.* 12, 1–42. <https://doi.org/10.3390/rs12203338>
- Albuquerque, A.O., de Carvalho, O.L.F., e Silva, C.R., de Bem, P.P., Trancoso Gomes, R.A., Borges, D.L., Guimarães, R.F., Pimentel, C.M.M., de Carvalho Júnior, O.A., 2021. Instance segmentation of center pivot irrigation systems using multi-temporal SENTINEL-1 SAR images. *Remote Sens. Appl. Soc. Environ.* 23, 100537. <https://doi.org/10.1016/j.rsase.2021.100537>
- Alpers, W., Holt, B., Zeng, K., 2017. Oil spill detection by imaging radars: Challenges and pitfalls. *Remote Sens. Environ.* 201, 133–147. <https://doi.org/10.1016/j.rse.2017.09.002>
- Bayramov, E., Kada, M., Buchroithner, M., 2018. Monitoring oil spill hotspots, contamination probability modelling and assessment of coastal impacts in the Caspian Sea using SENTINEL-1, LANDSAT-8, RADARSAT, ENVISAT and ERS satellite sensors. *J. Oper. Oceanogr.* 11, 27–43. <https://doi.org/10.1080/1755876X.2018.1438343>
- Bianchi, F.M., Espeseth, M.M., Borch, N., 2020. Large-Scale Detection and Categorization of



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

- Oil Spills from SAR Images with Deep Learning. *Remote Sens.* 12, 2260.  
<https://doi.org/10.3390/rs12142260>
- Brekke, C., Solberg, A.H.S., 2005. Oil spill detection by satellite remote sensing. *Remote Sens. Environ.* 95, 1–13. <https://doi.org/10.1016/j.rse.2004.11.015>
- Cantorna, D., Dafonte, C., Iglesias, A., Arcay, B., 2019. Oil spill segmentation in SAR images using convolutional neural networks. A comparative analysis with clustering and logistic regression algorithms. *Appl. Soft Comput.* 84, 105716.  
<https://doi.org/10.1016/j.asoc.2019.105716>
- Carvalho, O.L.F. de, de Carvalho Júnior, O.A., Albuquerque, A.O. de, Bem, P.P. de, Silva, C.R., Ferreira, P.H.G., Moura, R. dos S. de, Gomes, R.A.T., Guimarães, R.F., Borges, D.L., 2020. Instance Segmentation for Large, Multi-Channel Remote Sensing Imagery Using Mask-RCNN and a Mosaicking Approach. *Remote Sens.* 13, 39.  
<https://doi.org/10.3390/rs13010039>
- Chaturvedi, S.K., Banerjee, S., Lele, S., 2020. An assessment of oil spill detection using Sentinel 1 SAR-C images. *J. Ocean Eng. Sci.* 5, 116–135.  
<https://doi.org/10.1016/j.joes.2019.09.004>
- Chaurasia, A., Culurciello, E., 2017. LinkNet: Exploiting encoder representations for efficient semantic segmentation, in: 2017 IEEE Visual Communications and Image Processing (VCIP). IEEE, St. Petersburg, FL, USA, pp. 1–4.  
<https://doi.org/10.1109/VCIP.2017.8305148>
- Chen, G., Li, Y., Sun, G., Zhang, Y., 2017. Application of deep networks to oil spill detection using polarimetric synthetic aperture radar images. *Appl. Sci.* 7.  
<https://doi.org/10.3390/app7100968>
- Chen, L.-C., Papandreou, G., Kokkinos, I., Murphy, K., Yuille, A.L., 2018. DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs. *IEEE Trans. Pattern Anal. Mach. Intell.* 40, 834–848.  
<https://doi.org/10.1109/TPAMI.2017.2699184>
- Costa, M.V.C.V. da, Carvalho, O.L.F. de, Orlandi, A.G., Hirata, I., Albuquerque, A.O. De, Silva, F.V. e, Guimarães, R.F., Gomes, R.A.T., Júnior, O.A. de C., 2021. Remote Sensing for Monitoring Photovoltaic Solar Plants in Brazil Using Deep Semantic



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

- Segmentation. *Energies* 14, 2960. <https://doi.org/10.3390/en14102960>
- da Costa, L.B., de Carvalho, O.L.F., de Albuquerque, A.O., Gomes, R.A.T., Guimarães, R.F., de Carvalho Júnior, O.A., 2021. Deep semantic segmentation for detecting eucalyptus planted forests in the Brazilian territory using sentinel-2 imagery. *Geocarto Int.* 0, 1–13. <https://doi.org/10.1080/10106049.2021.1943009>
- de Albuquerque, A.O., de Carvalho Júnior, O.A., Carvalho, O.L.F. de, de Bem, P.P., Ferreira, P.H.G., de Moura, R. dos S., Silva, C.R., Trancoso Gomes, R.A., Fontes Guimarães, R., 2020. Deep Semantic Segmentation of Center Pivot Irrigation Systems from Remotely Sensed Data. *Remote Sens.* 12, 2159. <https://doi.org/10.3390/rs12132159>
- de Bem, P.P., de Carvalho Júnior, O.A.A., de Carvalho, O.L.F., Gomes, R.A.T., Fontes Guimarães, R., Guimarães, R.F., 2020. Performance Analysis of Deep Convolutional Autoencoders with Different Patch Sizes for Change Detection from Burnt Areas. *Remote Sens.* 12, 2576. <https://doi.org/10.3390/RS12162576>
- De Laurentiis, L., Jones, C.E., Holt, B., Schiavon, G., Frate, F. Del, 2020. Deep Learning for Mineral and Biogenic Oil Slick Classification With Airborne Synthetic Aperture Radar Data. *IEEE Trans. Geosci. Remote Sens.* 1–15. <https://doi.org/10.1109/TGRS.2020.3034722>
- de Moura, N.V.A., De Carvalho Júnior, O.A., Trancoso Gomes, R.A., Fontes Guimarães, R., 2020. Revisão sobre o uso de sensoriamento remoto na detecção de vazamentos de óleo no mar. *Caminhos Geogr.* 21, 214–224. <https://doi.org/10.14393/RCG217551341>
- Filippini, F., 2019. Sentinel-1 GRD Preprocessing Workflow. *Proceedings* 18, 11. <https://doi.org/10.3390/ecrs-3-06201>
- Fingas, M., Brown, C., 2014. Review of oil spill remote sensing. *Mar. Pollut. Bull.* 83, 9–23. <https://doi.org/10.1016/j.marpolbul.2014.03.059>
- Fingas, M., Brown, C.E., 2018. A review of oil spill remote sensing. *Sensors (Switzerland)* 18, 1–18. <https://doi.org/10.3390/s18010091>
- Fiscella, B., Giancaspro, A., Nirchio, F., Pavese, P., Trivero, P., 2000. Oil spill detection using marine SAR images. *Int. J. Remote Sens.* 21, 3561–3566. <https://doi.org/10.1080/014311600750037589>
- Gallego, A.J., Gil, P., Pertusa, A., Fisher, R.B., 2018. Segmentation of oil spills on side-



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

- looking airborne radar imagery with autoencoders. *Sensors* (Switzerland) 18.  
<https://doi.org/10.3390/s18030797>
- Gens, R., 2008. Oceanographic applications of SAR remote sensing. *GIScience Remote Sens.* 45, 275–305. <https://doi.org/10.2747/1548-1603.45.3.275>
- Guo, H., Wu, D., An, J., 2017. Discrimination of Oil Slicks and Lookalikes in Polarimetric SAR Images Using CNN. *Sensors* 17, 1837. <https://doi.org/10.3390/s17081837>
- Guo, Y., Liu, Y., Georgiou, T., Lew, M.S., 2018. A review of semantic segmentation using deep neural networks. *Int. J. Multimed. Inf. Retr.* 7, 87–93.  
<https://doi.org/10.1007/s13735-017-0141-z>
- He, K., Zhang, X., Ren, S., Sun, J., 2016. Deep Residual Learning for Image Recognition, in: 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, Las Vegas, NV, USA, pp. 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- Heller, N., Dean, J., Papanikolopoulos, N., 2018. Imperfect Segmentation Labels: How Much Do They Matter?, in: *Intravascular Imaging and Computer Assisted Stenting and Large-Scale Annotation of Biomedical Data and Expert Label Synthesis. LABELS 2018, CVII 2018, STENT 2018. Lecture Notes in Computer Science.* Springer, Cham, pp. 112–120.  
[https://doi.org/10.1007/978-3-030-01364-6\\_13](https://doi.org/10.1007/978-3-030-01364-6_13)
- Jiao, Z., Jia, G., Cai, Y., 2019. A new approach to oil spill detection that combines deep learning with unmanned aerial vehicles. *Comput. Ind. Eng.* 135, 1300–1311.  
<https://doi.org/10.1016/j.cie.2018.11.008>
- Kang, H., Meng, J., Cheng, T., Jia, H., Bai, B., Li, M., 2018. Characteristics of deep water depositional system in Campos basin, Brazil. *Pet. Explor. Dev.* 45, 99–110.  
[https://doi.org/10.1016/S1876-3804\(18\)30009-0](https://doi.org/10.1016/S1876-3804(18)30009-0)
- Krestenitis, M., Orfanidis, G., Ioannidis, K., Avgerinakis, K., Vrochidis, S., Kompatsiaris, I., 2019. Oil spill identification from satellite images using deep neural networks. *Remote Sens.* 11, 1–22. <https://doi.org/10.3390/rs11151762>
- Leifer, I., Lehr, W.J., Simecek-Beatty, D., Bradley, E., Clark, R., Dennison, P., Hu, Y., Matheson, S., Jones, C.E., Holt, B., Reif, M., Roberts, D.A., Svejksky, J., Swayze, G., Wozencraft, J., 2012. State of the art satellite and airborne marine oil spill remote sensing: Application to the BP Deepwater Horizon oil spill. *Remote Sens. Environ.* 124,



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

- 185–209. <https://doi.org/10.1016/j.rse.2012.03.024>
- Li, X., Liu, B., Zheng, G., Ren, Y., Zhang, S., Liu, Yingjie, Gao, L., Liu, Yuhai, Zhang, B., Wang, F., 2020. Deep learning-based information mining from ocean remote sensing imagery. *Natl. Sci. Rev.* nwaa047. <https://doi.org/10.1093/nsr/nwaa047>
- Ma, L., Liu, Y., Zhang, X., Ye, Y., Yin, G., Johnson, B.A., 2019. Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS J. Photogramm. Remote Sens.* 152, 166–177. <https://doi.org/10.1016/j.isprsjprs.2019.04.015>
- Marghany, M., 2001. RADARSAT automatic algorithms for detecting coastal oil spill pollution. *Int. J. Appl. Earth Obs. Geoinf.* 3, 191–196. [https://doi.org/10.1016/S0303-2434\(01\)85011-X](https://doi.org/10.1016/S0303-2434(01)85011-X)
- Mou, L., Zhu, X.X., 2018. Vehicle Instance Segmentation From Aerial Image and Video Using a Multitask Learning Residual Fully Convolutional Network. *IEEE Trans. Geosci. Remote Sens.* 56, 6699–6711. <https://doi.org/10.1109/TGRS.2018.2841808>
- Nieto-Hidalgo, M., Gallego, A.J., Gil, P., Pertusa, A., 2018. Two-stage convolutional neural network for ship and spill detection using SLAR images. *IEEE Trans. Geosci. Remote Sens.* 56, 5217–5230. <https://doi.org/10.1109/TGRS.2018.2812619>
- Pisano, A., De Dominicis, M., Biamino, W., Bignami, F., Gherardi, S., Colao, F., Coppini, G., Marullo, S., Sprovieri, M., Trivero, P., Zambianchi, E., Santoleri, R., 2016. An oceanographic survey for oil spill monitoring and model forecasting validation using remote sensing and in situ data in the Mediterranean Sea. *Deep Sea Res. Part II Top. Stud. Oceanogr.* 133, 132–145. <https://doi.org/10.1016/j.dsr2.2016.02.013>
- Ronneberger, O., Fischer, P., Brox, T., 2015. U-Net: Convolutional Networks for Biomedical Image Segmentation, in: Navab, N., Hornegger, J., Wells, W., Frangi, A. (Eds.), *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. Springer, Cham, pp. 234–241. [https://doi.org/10.1007/978-3-319-24574-4\\_28](https://doi.org/10.1007/978-3-319-24574-4_28)
- Solberg, A.H.S., 2012. Remote sensing of ocean oil-spill pollution. *Proc. IEEE* 100, 2931–2945. <https://doi.org/10.1109/JPROC.2012.2196250>
- Tan, M., Le, Q. V., 2019. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. *arXiv*.



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

- Tong, K., Wu, Y., Zhou, F., 2020. Recent advances in small object detection based on deep learning: A review. *Image Vis. Comput.* 97, 103910.  
<https://doi.org/10.1016/j.imavis.2020.103910>
- Vasconcelos, R.N., Lima, A.T.C., Lentini, C.A.D., Miranda, G. V., Mendonça, L.F., Silva, M.A., Cambuí, E.C.B., Lopes, J.M., Porsani, M.J., 2020. Oil spill detection and mapping: A 50-year bibliometric analysis. *Remote Sens.* 12, 1–18.  
<https://doi.org/10.3390/rs12213647>
- Wang, X., Liu, J., Zhang, S., Deng, Q., Wang, Z., Li, Y., Fan, J., 2021. Detection of Oil Spill Using SAR Imagery Based on AlexNet Model. *Comput. Intell. Neurosci.* 2021.  
<https://doi.org/10.1155/2021/4812979>
- Yakubovskiy, P., 2020. Segmentation Models Pytorch. GitHub Repos.
- Yekeen, S.T., Balogun, A.A.L., Wan Yusof, K.B., Temitope Yekeen, S., Balogun, A.A.L., Wan Yusof, K.B., 2020. A novel deep learning instance segmentation model for automated marine oil spill detection. *ISPRS J. Photogramm. Remote Sens.* 167, 190–200. <https://doi.org/10.1016/j.isprsjprs.2020.07.011>
- Yekeen, S.T., Balogun, A.L., 2020. Advances in remote sensing technology, machine learning and deep learning for marine oil spill detection, prediction and vulnerability assessment. *Remote Sens.* 12, 1–31. <https://doi.org/10.3390/rs12203416>
- Yuan, Q., Shen, H., Li, T., Li, Z., Li, S., Jiang, Y., Xu, H., Tan, W., Yang, Q., Wang, J., Gao, J., Zhang, L., 2020. Deep learning in environmental remote sensing: Achievements and challenges. *Remote Sens. Environ.* 241, 111716.  
<https://doi.org/10.1016/j.rse.2020.111716>
- Zeng, K., Wang, Y., 2020. A deep convolutional neural network for oil spill detection from spaceborne SAR images. *Remote Sens.* 12. <https://doi.org/10.3390/rs12061015>
- Zhang, Y., Li, Y., Lin, H., 2014. Oil-Spill Pollution Remote Sensing by Synthetic Aperture Radar, in: *Advanced Geoscience Remote Sensing*. InTech. <https://doi.org/10.5772/57477>
- Zhu, X., Li, Y., Zhang, Q., Liu, B., 2019. Oil film classification using deep learning-based hyperspectral remote sensing technology. *ISPRS Int. J. Geo-Information* 8.  
<https://doi.org/10.3390/ijgi8040181>



## CAPÍTULO V

### CONCLUSÃO

O Sensoriamento Remoto é uma tecnologia eficiente para monitorar a presença de óleo na superfície do mar, sendo extremamente útil para auxiliar a gestão de desastres e subsidiar a tomada de decisões, principalmente no fornecimento de informações essenciais para a adoção de medidas de controle, tais como: Qual a quantidade de óleo vazado? Qual o regime de vazamento? Qual a velocidade de deslocamento do óleo da superfície? Qual é a velocidade da intemperização? Qual é o provável destino?

Além de atuar como instrumento de coação contra derramamentos intencionais, servir como prova para ações judiciais contra os responsáveis por esses eventos e atuar na identificação e mapeamentos de áreas de recorrência de vazamentos.

No entanto, o Brasil não dispõe no momento dos insumos necessários para a realização dessa tarefa. A missão Sentinel-1 da ESA é a única fonte gratuita de imagens de radar disponíveis. No entanto, em dezembro de 2021 a ESA informou a existência de problemas operacionais no satélite Sentinel-1B, e alguns meses depois sua total inoperância. O satélite Sentinel-1A continua em operação, apesar de já ter ultrapassado sua previsão de vida útil, no entanto, ele somente gera imagens a cada 12 dias do litoral da região Nordeste. Ou seja, o litoral sudeste do país, a maior área produtora de petróleo, encontra-se sem cobertura da Missão Sentinel 1.

O maior desafio encontrado ao longo da pesquisa foi a falta de dados governamentais confiáveis sobre as ocorrências de vazamentos. As fontes pesquisadas são incompletas, desorganizadas e discrepantes entre si. O que tornou difícil a tarefa de qualificar os vazamentos detectados nas imagens de radar, fato que por sua vez limita a acurácia dos sistemas automatizados de detecção.

A aplicação de *Deep Learning* realizada no presente estudo é pioneira no país. Tendo alcançado resultados nos mesmos patamares de pesquisas realizadas em todo o mundo em instituições especializadas na temática. Foi possível mapear de maneira acurada os locais com



Universidade de Brasília  
Instituto de Ciências Humanas  
Departamento de Geografia  
Programa de Pós-Graduação em Geografia

maior incidência de vazamentos. Esses dados podem contribuir para a gestão ambiental das plataformas de petróleo.

Para o futuro, espera-se expandir a pesquisa para outras áreas produtoras de petróleo do país, em especial a Bacia de Santos, para as áreas que são rotas de embarcações e para aquelas com presença de oleodutos submarinos. Outro ponto previsto para etapa posterior diz respeito ao acompanhamento da disponibilização de novos insumos gratuitos de sensoriamento remoto, sobretudo de satélites que operam na Banda L, que têm subsidiado cada vez mais pesquisas sobre o monitoramento de óleo no mar em outros locais do mundo.

Espera-se que a tese possa contribuir para o monitoramento dos vazamentos de óleo e para o gerenciamento de acidentes que representam risco para o meio ambiente marítimo e costeiro, para as populações litorâneas e suas atividades sociais e econômicas, de forma rápida e efetiva.

Por fim, registra-se que a pandemia de COVID-19, causou uma interrupção na tendência de consumo crescente de petróleo em todo o mundo, por consequência, caiu o número de vazamentos de óleo. Ao mesmo tempo, o evento trágico para toda a humanidade, trouxe a necessidade de repensar padrões de consumo e a forma de tratamento do planeta. Dessa forma, faz-se necessário acompanhar nos próximos anos qual será o padrão das ocorrências envolvendo o derramamento de óleo no mar, considerando esse evento que modificou a série histórica.